

T.C.
MUNZUR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM
ENSTİTÜSÜ



DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
ÇEVİRİMİÇİ SOSYAL AĞLARDA DEPRESYON VE İNTİHAR TESPİTİ

Fatoş ORĞUN

YÜKSEK LİSANS TEZİ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK ANABİLİM DALI

DANIŞMAN
Dr. Öğr. Üyesi Ümit CAN

TUNCELİ - 2025

T.C.
MUNZUR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM
ENSTİTÜSÜ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
ÇEVİRİMİÇİ SOSYAL AĞLARDA DEPRESYON VE İNTİHAR TESPİTİ

Fatoş ORĞUN
(220210012)

YÜKSEK LİSANS TEZİ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK ANABİLİM DALI

DANIŞMAN
Dr. Öğr. Üyesi Ümit Can

TUNCELİ - 2025

T.C.
MUNZUR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM
ENSTİTÜSÜ

**DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
ÇEVİRİMİÇİ SOSYAL AĞLARDA DEPRESYON VE İNTİHAR TESPİTİ**

Fatoş ORĞUN
YÜKSEK LİSANS TEZİ
HESAPLAMALI BİLİMLER VE MÜHENDİSLİK ANABİLİM DALI

Bu tez 07/01/2025 tarihinde aşağıdaki jüri üyeleri tarafından **oybirliği/oyçokluğu** ile kabul edilmiştir.

İmza	İmza	İmza
Doç. Dr. Anıl UTKU (Munzur Üniversitesi)	Dr. Öğr. Üyesi Ümit CAN (Munzur Üniversitesi)	Doç. Dr. Serpil Aslan (Munzur Üniversitesi)
Başkan	Danışman	Üye

Bu tez, Enstitümüz Hesaplamalı Bilimler ve Mühendislik Anabilim Dalı'nda hazırlanmıştır.

Enstitü Müdürü
Prof. Dr. Altuğ KAZAR

NOT: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı “Fikir ve Sanat Eserleri Kanunu”ndaki hükümlere tabidir.

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

İmza

Fatoş ORĞUN

Danışman

Dr. Öğr. Üyesi Ümit Can

TEŞEKKÜR

Öncelikle, çalışmalarım esnasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemedi beni her konuda yönlendiren danışman hocam Ümit CAN'a teşekkür ederim. Ayrıca sevgili eşim Mehmet Ali'ye, sevgili kardeşim Dilan'a teşekkür ederim. Bu süreçte destek ve sabırlarını esirgemeyip hep yanımda hissettirdiler.

Fatoş ORĞUN
TUNCELİ-2025



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	i
TEŞEKKÜR.....	ii
İÇİNDEKİLER.....	iii
ŞEKİLLER LİSTESİ.....	v
TABLolar LİSTESİ.....	vii
KISALTMALAR LİSTESİ.....	x
ÖZET.....	xii
ABSTRACT.....	xiii
1. GİRİŞ	1
1.1. İntihar ve Depresyon Nedir?.....	1
1.2. Çevrimiçi Sosyal Ağlar	2
1.3. Depresyon ve İntiharın Çevrimiçi Sosyal Ağlarda Tespiti.....	5
1.4. Literatür Taraması	6
1.5. Çalışma Hakkında.....	13
2. MATERYAL VE METOT.....	15
2.1. Kullanılan Derin Öğrenme ve Makine Öğrenmesi Yöntemleri.....	15
2.2. Veri Seti.....	21
2.3. İntihar Tespiti Uygulama Adımları	23
2.3.1. Veri ön işleme.....	24
2.3.2. Verilerin vektörleştirilmesi.....	25
2.3.3. Özellik ölçeklendirme	25
2.4. Derin Öğrenme Modellerinin Hiperparametreleri	25
2.5. Sınıflandırma Performans Metrikleri.....	27
2.6. Deneysel Sonuçlar	28
2.6.1. Suicide ideation veri seti için makine öğrenmesi modellerinin sonuçları.....	28
2.6.2. Suicide Ideation veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları.....	30
2.6.3. Reddit Depression Suicidewatch veri seti için makine öğrenmesi modellerinin sonuçları	33
2.6.4. Reddit Depression Suicidewatch veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları	35

2.6.5. Suicide Detection veri seti için makine öğrenmesi modellerinin sonuçları	38
2.6.6. Suicide Detection veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları	40
2.6.7. İncelenen üç veri setinin karşılaştırmalı sonuçları	43
2.6.8. Suicide Ideation veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları	45
2.6.10. Reddit Depression Suicidewatch veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları	50
2.6.11. Reddit Depression Suicidewatch veri seti için grid search uygulanan derin öğrenme modellerinin sonuçları	52
2.6.12. Suicide Detection veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları	55
2.6.13. Suicide Detection veri seti için Grid Search uygulanan derin öğrenme modellerinin sonuçları	57
2.6.14. İncelenen üç veri setinin karşılaştırmalı Grid Search sonuçları	61
2.6.15. Derin öğrenme yöntemlerinin parametreleri	63
3. SONUÇ VE ÖNERİLER	65
4.KAYNAKLAR.....	66
ÖZGEÇMİŞ	71

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Örnek bir sosyal ağ yapısı.....	3
Şekil 1.2. 2024 yılındaki en popüler çevrimiçi sosyal ağlar ve kullanıcı sayıları.....	4
Şekil 2.1. FastText Modeli.....	15
Şekil 2.2. Basit tekrarlayan sinir ağı yapısı.....	16
Şekil 2.3. DBN mimarisi.....	16
Şekil 2.4. Kelime bazında sınıf tahmini yaparken kullanılan CNN çerçevesi.....	17
Şekil 2.5. Temel LSTM mimarisi	17
Şekil 2.6. NB yönteminin olasılıklar yaklaşımı	18
Şekil 2.7. Lojistik Regresyon ile sınıflandırma örneği	18
Şekil 2.8. Random Forest.....	19
Şekil 2.9. Decision Tree	20
Şekil 2.10. k-NN yöntemi	20
Şekil 2.11. Veri setindeki 'Tweet' ve 'Suicide' iki sütun sayısı	21
Şekil 2.12. Veri setindeki 'text' ve 'label' iki sütun sayısı	22
Şekil 2.13. Veri setindeki 'text' ve 'class' iki sütun sayısı	23
Şekil 2.14. Uygulanan modellerin genel mimarisi.....	23
Şekil 2.15. Derin öğrenme uygulamalarında parametre ve hiperparametre.....	26
Şekil 2.16. En popüler aktivasyon fonksiyonlarının grafikleri	27
Şekil 2.17. ANN için train loss ve validation accuracy grafikleri	30
Şekil 2.18. LSTM için validation loss ve validation accuracy grafikleri.....	31
Şekil 2.19. DBN için training accuracy ve testing accuracy grafikleri.....	32
Şekil 2.20. CNN için validation accuracy ve validation loss grafikleri	33
Şekil 2.21. ANN için training accuracy ve test accuracy grafikleri.....	35
Şekil 2.22. LSTM için training loss ve training accuracy grafikleri.....	36
Şekil 2.23. DBN training validation ve test validation grafikleri	37
Şekil 2.24. CNN için training accuracy ve training loss grafikleri	38
Şekil 2.25. CNN için training accuracy ve training loss grafikleri	40
Şekil 2.26. LSTM için training accuracy ve training accuracy grafikleri.....	41
Şekil 2.27. DBN için training loss ve validation accuracy grafikleri	42
Şekil 2.28. ANN için training accuracy ve test accuracy grafikleri.....	43
Şekil 2.29. ANN için training loss ve validation accuracy grafikleri	47

Şekil 2.30. LSTM için training loss ve training accuracy grafikleri.....	48
Şekil 2.31. DBN için training accuracy ve testing accuracy grafikleri.....	49
Şekil 2.32. CNN için training accuracy ve training loss grafikleri	50
Şekil 2.33. ANN için training accuracy ve test accuracy grafikleri.....	52
Şekil 2.34. LSTM için training loss ve training accuracy grafikleri.....	53
Şekil 2.35. DBN için training loss ve validation accuracy grafikleri	54
Şekil 2.36. CNN için training accuracy ve validation accuracy grafikleri.....	55
Şekil 2.37. CNN için training accuracy ve training loss grafikleri	58
Şekil 2.38. LSTM için training loss ve training accuracy grafikleri.....	59
Şekil 2.39. DBN için education loss ve validation accuracy grafikleri	60
Şekil 2.40. ANN için training loss ve validation accuracy grafikleri	61

TABLÖLER LİSTESİ

	<u>Sayfa</u>
Tablo 2.1. LR'nin karmaşıklık matrisi	28
Tablo 2.2. NB'nin karmaşıklık matrisi.....	28
Tablo 2.3. RF'nin karmaşıklık matrisi	29
Tablo 2.4. DT'nin karmaşıklık matrisi.....	29
Tablo 2.5. KNN'nin karmaşıklık matrisi	29
Tablo 2.6. FastText için ANN'nin karmaşıklık matrisi	30
Tablo 2.7. FastText için LSTM'in karmaşıklık matrisi	31
Tablo 2.8. FastText için DBN'nin karmaşıklık matrisi.....	31
Tablo 2.9. FastText için CNN'nin karmaşıklık matrisi.....	32
Tablo 2.10. LR'nin karmaşıklık matrisi	33
Tablo 2.11. NB'nin karmaşıklık matrisi.....	33
Tablo 2.12. RF'nin karmaşıklık matrisi	34
Tablo 2.13. DT'nin karmaşıklık matrisi.....	34
Tablo 2.14. KNN'nin karmaşıklık matrisi	34
Tablo 2.15. FastText için ANN'nin karmaşıklık matrisi	35
Tablo 2.16. FastText için LSTM'nin karmaşıklık matrisi	36
Tablo 2.17. FastText için DBN'nin karmaşıklık matrisi.....	36
Tablo 2.18. FastText için CNN'nin karmaşıklık matrisi.....	37
Tablo 2.19. LR'nin karmaşıklık matrisi	38
Tablo 2.20. NB'nin karmaşıklık matrisi.....	38
Tablo 2.21. RF'nin karmaşıklık matrisi	39
Tablo 2.22. DT'nin karmaşıklık matrisi.....	39
Tablo 2.23. KNN'nin karmaşıklık matrisi	39
Tablo 2.24. FastText için CNN'nin karmaşıklık matrisi.....	40
Tablo 2.25. FastText için LSTM'nin karmaşıklık matrisi	41
Tablo 2.26. FastText için DBN'nin karmaşıklık matrisi.....	41
Tablo 2.27. FastText için ANN'nin karmaşıklık matrisi	42
Tablo 2.28. Suicide Ideation veri seti için yöntemlerin karşılaştırmalı sonuçları	43
Tablo 2.29. Reddit Depression Suicidewatch veri seti için yöntemlerin karşılaştırmalı sonuçları	44
Tablo 2.30. Suicide Detection veri seti için yöntemlerin karşılaştırmalı sonuçları.....	44

Tablo 2.31. LR'nin karmaşıklık matrisi	45
Tablo 2.32. NB'nin karmaşıklık matrisi.....	45
Tablo 2.33. RF'nin karmaşıklık matrisi	45
Tablo 2.34. DT'nin karmaşıklık matrisi.....	46
Tablo 2.35. KNN'nin karmaşıklık matrisi	46
Tablo 2.36. ANN'nin karmaşıklık matrisi	47
Tablo 2.37. LSTM'nin karmaşıklık matrisi	47
Tablo 2.38. DBN'nin karmaşıklık matrisi.....	48
Tablo 2.39. CNN'nin karmaşıklık matrisi.....	49
Tablo 2.40. LR'nin karmaşıklık matrisi	50
Tablo 2.41. NB'nin karmaşıklık matrisi.....	50
Tablo 2.42. RF'nin karmaşıklık matrisi	51
Tablo 2.43. DT'nin karmaşıklık matrisi.....	51
Tablo 2.44. KNN'nin karmaşıklık matrisi	51
Tablo 2.45. ANN'nin karmaşıklık matrisi	52
Tablo 2.46. LSTM'nin karmaşıklık matrisi	53
Tablo 2.47. DBN'nin karmaşıklık matrisi.....	53
Tablo 2.48. CNN'nin karmaşıklık matrisi.....	55
Tablo 2.49. LR'nin karmaşıklık matrisi	55
Tablo 2.50. NB'nin karmaşıklık matrisi.....	56
Tablo 2.51. RF'nin karmaşıklık matrisi	56
Tablo 2.52. DT'nin karmaşıklık matrisi.....	56
Tablo 2.53. KNN'nin karmaşıklık matrisi	57
Tablo 2.54. CNN'nin karmaşıklık matrisi.....	57
Tablo 2.55. LSTM'nin karmaşıklık matrisi	58
Tablo 2.56. DBN'nin karmaşıklık matrisi.....	59
Tablo 2.57. ANN'nin karmaşıklık matrisi	60
Tablo 2.58. Suicide Ideation veri seti için yöntemlerin karşılaştırmalı sonuçları	62
Tablo 2.59. Reddit Depression Suicidewatch veri seti için yöntemlerin karşılaştırmalı sonuçları	62
Tablo 2.60. Suicide Detection veri seti için yöntemlerin karşılaştırmalı sonuçları.....	63
Tablo 2.61. Suicide Ideation veri seti için derin öğrenme yöntemlerinin parametreleri	63
Tablo 2.62. Reddit Depression Suicidewatch veri seti için derin öğrenme yöntemlerinin parametreleri.....	63

Tablo 2.63. Suicide Detection veri seti için derin öğrenme yöntemlerinin parametreleri..... 64



KISALTMALAR LİSTESİ

ANN	: Artificial Neural Networks
ANOVA	: Varyans Analizi
BERT	: Bidirectional Encoder Representations from Transformers
BoW	: Kelime Torbası
CBOW	: Continuous Bag of Words
CNN	: Convolutional Neural Networks
ÇSA	: Çevrimiçi Sosyal Ağ
DBN	: Deep Belief Networks
DT	: Decision Tree
FN	: False Negative
FP	: False Positive
GRU	: Gated Recurrent Units
k-NN	: k-en yakın komşu
LIWC	: Dilbilimsel Sorgulama ve Kelime Sayımı
LR	: Logistic Regresyon
LSTM	: Long Short-Term Memory
MLP	: Çok Katmanlı Algılayıcı
MNB	: Multinomial Naive Bayes
NB	: Naive Bayes
NLP	: Doğal Dil İşleme
PA	: Pasif Agresif
PHQ-9	: Hasta Sağlık Anketi-9
PSPO	: Proactive Suicide Prevention Online
RF	: Random Forest
RNN	: Recurrent Neural Network
SGD	: Stokastik Gradyan İnişli
SLR	: Sign Language Recognition
SVM	: Support Vector Machine
SVM-RFE	: Destek Vektör Makinesi - Tekrarlayan Özellik Eleme
TF-IDF	: Term Frequency-Inverse Document Frequency
TN	: True Negative

TP : True Positive
WHO : Dünya Sağlık Örgütü



ÖZET

Bu tez çalışmasında, çevrimiçi sosyal ağlarda (ÇSA) gönderi paylaşan depresyondaki kişilerin intihar düşüncelerini tespit etmek ve intihar edip etmeyeceklerini tahmin etmek için derin öğrenme ve makine öğrenmesi tabanlı metin sınıflandırıcı modeller oluşturulmuştur. Çalışmada Suicide Ideation, Reddit Depression Suicidewatch ve Suicide Detection olmak üzere üç ayrı veri seti kullanılmıştır. Suicide Ideation veri seti için ‘Potential suicide post’ ve ‘Not suicide post’, Reddit Depression Suicidewatch veri seti için ‘Depression’ ve ‘SuicideWatch’, Suicide Detection veri seti için ise ‘Suicide’ ve ‘Non-suicide’ etiketleri bulunmaktadır. Bu veri setleri binary sınıflandırma görevi için derin öğrenme ve makine öğrenimi modellerinin geliştirilmesini ve değerlendirilmesini kolaylaştırmaktır. Bu çalışmada Artificial Neural Networks (ANN), Deep Belief Networks (DBN), Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), FastText, Naive Bayes (NB), Logistic Regression (LR), k-en yakın komşu (k-NN), Random Forest (RF) ve Decision Tree (DT) yöntemleri kullanılarak intihar düşüncesi tahmin modelleri oluşturulmuş makine öğrenmesi yöntemlerine TF-IDF ve derin öğrenme modellerine ise FastText uygulanmıştır. Ayrıca hiperparametre optimizasyonu için bütün algoritmalara Grid Search yöntemi uygulanarak sonuçlar karşılaştırılmıştır. Tez çalışmasının ilk karşılaştırmalar sonucunda Suicide Ideation veri setinde %94 oranıyla RF modeli, Reddit Depression Suicidewatch veri setinde %73 oranıyla LR modeli ve Suicide Detection veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur. Grid Search metriği uygulandıktan sonraki karşılaştırmalar sonucunda ise Suicide Ideation veri setinde %94 oranıyla RF modeli, Reddit Depression Suicidewatch veri setinde %74 oranıyla ANN modeli ve Suicide Ideation veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur.

Anahtar kelimeler: Derin öğrenme, makine öğrenmesi, çevrimiçi sosyal ağlar, intihar tespiti, veri madenciliği.

ABSTRACT

Depression and Suicide Detection in Online Social Networks with Deep Learning and Machine Learning Methods

In this thesis, deep learning and machine learning based text classifier models are built to detect suicidal thoughts of depressed people who post on online social networks (ASNs) and predict whether they will commit suicide. Three separate datasets, Suicide Ideation, Reddit Depression Suicidewatch and Suicide Detection, were used in the study. Suicide Ideation dataset is labeled as 'Potential suicide post' and 'Not suicide post', Reddit Depression Suicidewatch dataset is labeled as 'Depression' and 'SuicideWatch', and Suicide Detection dataset is labeled as 'Suicide' and 'Non-suicide'. These datasets facilitate the development and evaluation of deep learning and machine learning models for the binary classification task. In this study, Artificial Neural Networks (ANN), Deep Belief Networks (DBN), Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), FastText, Naive Bayes (NB), Logistic Regression (LR), k-nearest neighbor (k-NN), Random Forest (RF) and Decision Tree (DT) methods were used to build suicidal ideation prediction models, and TF-IDF was applied to machine learning methods and FastText to deep learning models. In addition, Grid Search method was applied to all algorithms for hyperparameter optimization and the results were compared. As a result of the first comparisons of the thesis study, RF model with 94% in Suicide Ideation dataset, LR model with 73% in Reddit Depression Suicidewatch dataset and ANN and LR with 93% in Suicide Detection dataset were the most successful models. After applying the Grid Search metric, RF model with 94% in Suicide Ideation dataset, ANN model with 74% in Reddit Depression Suicidewatch dataset and ANN and LR with 93% in Suicide Ideation dataset were the most successful models.

Keywords: Deep learning, machine learning, online social networks, suicide detection, data mining.

1. GİRİŞ

İntihar düşüncesi, anksiyete ve depresyon, ergenler ve genç yetişkinler arasında en yaygın ruh sağlığı bozukluklarından bazılarıdır ve her yıl yaklaşık olarak 800.000 kişi intihar sonucu ölmektedir (URL-1). Neyse ki, son yıllarda bu gerçeğin giderek daha fazla farkına varılmış ve gençlerin erken bir aşamadan itibaren ruhsal dayanıklılık geliştirmelerini sağlamanın önemi daha iyi anlaşılmıştır. İletişim toplumun kalbinde yer almaktadır ve şu anda yazılı dijital iletişim kendini ifade etmenin en popüler biçimlerinden biridir. Sosyal ağlar, insan faaliyetlerini veya rutinlerini detaylandırmak, duygularını, zihinsel durumlarını ve arzularını tanımlamak için kullanılmaktadır (Calvo ve ark., 1994). Sosyal medyanın yaygınlaşan kullanımı, ruh sağlığı bozukluklarının erken tespitini güçlendirme potansiyeline sahiptir. Sosyal medya aracılığıyla toplanan veriler dijital olduğu için ruh sağlığı analizlerini daha da hızlandırma kabiliyetine sahiptir. Bu alanda ki eski çalışmalar, Twitter'daki kısa metinlerin bile dil ve ruh sağlığı koşulları arasındaki ilişki hakkında bazı bilgiler sağlayabileceğini göstermiş olsa da, şu anda daha fazla bilgi edinmek için daha uzun biçimli içerikler araştırılmaktadır (Trifan ve ark., 2020).

1.1. İntihar ve Depresyon Nedir?

Depresyon, günlük yaşama, çalışma, uyuma, yemek yeme ve hayattan zevk alma becerisine müdahale eden yaygın ama ciddi bir hastalıktır. Depresyon genetik, biyolojik, çevresel ve psikolojik faktörlerin bir kombinasyonundan kaynaklanır. Bazı genetik araştırmalar, depresyon riskinin, çevresel veya diğer faktörlerle birlikte hareket eden birkaç genin etkisinden kaynaklandığını göstermektedir. Bazı depresyon türleri ailelerde görülme eğilimindedir. Bununla birlikte, ailede depresyon öyküsü olmayan kişilerde de depresyon görülebilir. Depresif hastalığı olan kişilerin hepsi aynı semptomları yaşamaz. Semptomların şiddeti, sıklığı ve süresi kişiye ve onun özel hastalığına bağlı olarak değişir (URL-2). Depresyon, duygusal, bilişsel ve fiziksel belirtilerle bütünleşmiş bir duygu bozukluğu olarak nitelendirilmiştir. Dünya Sağlık Örgütü'ne (WHO) göre, depresyon, devamlı üzüntü hali, ilgi kaybı ve motivasyon düşüklüğü gibi belirtilerle tanımlanmıştır (URL-3). Depresyon, kişinin günlük sorumluluklarını yerine getirmesini zorlaştırabilir ve yaşam kalitesini ciddi oranda düşürebilir. Bu süreç genellikle iki hafta veya daha fazla sürer ve bireyin işlevselliğini son derece etkiler (URL-4).

Depresyonun nedenleri genellikle biyolojik, psikolojik ve sosyal faktörlerin etkileşimi şeklinde açıklanır. Biyolojik açıdan, serotonin, norepinefrin vb. dengesizlikleri,

genetik yatkınlık ve beyin yapısındaki değişiklikler önemli rol oynamaktadır (URL-5). Psikolojik faktörler arasında, kişinin düşünce yapısı, travmatik yaşam tecrübeleri ve düşük öz saygısı sayılabilir (URL-6). Sosyal faktör olarak ise, aile içi ilişkilerdeki problemler, sosyal destek eksikliği ve ekonomik zorluklar gibi unsurları içerir (URL-7).


Depresyon, intihar riskini büyük oranda artıran bir faktördür. Yapılan araştırmalar, intihar eden kişilerin çoğunlukla ölümden önce depresyon belirtileri gösterdiğini ortaya koymaktadır (URL-8). Depresyonun, kişinin yaşamdan zevk almasını ve umut duygusunu yitirmesine yol açması, intiharı bir kurtuluş yolu olarak görmesine sebep olabilir (URL-9). İntihar riski, kişilerin özellikle tedavi olmadığı depresyon durumlarında daha yüksektir (Hegerl ve ark., 2009). İntihar, kişinin istemli şekilde kendisinin ölümüne yol açma eylemi olarak tanımlanabilir. Sıklıkla çaresizlik hissinin sonucu olarak ortaya çıkar ve büyük oranda depresyon, bipolar bozukluk, şizofreni, alkolizm ve maddenin kötüye kullanımı gibi çeşitli sorunlarla ilişkili olarak görülür. Maddi sorunlar ve kişiler arası çatışmalar intihara sebebiyet veren stres etmenlerinin başında gelir. Peki, bir kişinin intihar girişiminde bulunacağını anlamamanın yolları var mıdır? İntiharların çoğunda girişimin hemen öncesinde uyarıcı bazı belirtiler geriye dönük olarak tespit edilebilse de, intiharın kesin olarak önceden tahmininin her zaman mümkün olmadığını kabul etmek gerekir. Ancak bazı belirtilerin özellikle ciddiye alınarak kişinin psikiyatrist tarafından değerlendirilmesi sağlanmalıdır (Arıkan, 2023).

İntiharın önlenmesi için, depresyonun erken tanı ve tedavisi büyük önem taşır. Kişilerin intihar edip etmeyeceğini anlamak için dikkatli bir değerlendirme yapmak gereklidir. Ruh sağlığı uzmanları, kişilerin risk faktörlerini göz önüne almalı ve gerekli müdahaleleri yapmalıdır (Mann ve ark., 2005). İlaç tedavisi, psikolojik terapi ve sosyal destek yapılarının güçlendirilmesi, intiharın önlenmesinde etkili faktörler arasında yer almıştır (Hawton ve ark., 2009).

1.2. Çevrimiçi Sosyal Ağlar

İnternet ortamında, kullanıcıların kendilerini tanımlayarak her kültürden farklı kullanıcı ile iletişime geçtiği, bunun yanında normal sosyal yaşamda kullanılan jest ve mimik hareketlerini simgeleyen sembollerle duygu ve düşüncelerini sanal olarak ifade ettiği, bu şekilde sosyal iletişim kurduğu ortamlar ÇSA olarak tanımlanmaktadır. Bugün sosyal ağlar dediğimizde en büyük örnek olarak karşımıza Facebook, Instagram, Twitter ve LinkedIN gibi platformlar çıkmaktadır. Sosyal ağlar bireylerin kendilerini internet

üzerinden tanımlamalarına olanak tanır. Bu ağlar vasıtasıyla kişiler farklı sosyal topluluklara üye olur ve orada her türlü fikirlerini rahatça paylaşabilir. Bunu yaparken çeşitli jestleri simgeleyen sembolik hareketleride gönderilere ekleyebilirler. Bu bağlamda ÇSA'lar giderek yayılmakta ve kullanımı bireyler ve toplumlar için gerekli bir hale gelmektedir. Bu ağlardaki bireyler arasında iletişimin şekli ve gönderi türleri kişiler hakkında önemli birçok bilgiyi barındırır. Bu bilgiler sosyal ağ analizi yöntemleri ile analiz edilerek birçok disiplinde kullanılacak bilgiler açığa çıkartılabilir (Wellman, 2021 Şekil 1.1.'de örnek bir sosyal ağ yapısı gösterilmiştir.




Şekil 1.1. Örnek bir sosyal ağ yapısı

Günümüzde ÇSA, topluluk oluşturma, iletişim kurma, bilgi paylaşma yapılarını derin bir şekilde değiştirmiştir. Bu ağlar, dijital dünyada uzun soluklu sosyal yapılar kurarak, içerik paylaşımına olanak tanır ve sosyal yapıları dijital ortamda temsil eder. Bu şekilde, çevrimiçi sosyal ağların yapısı, modern ağ teorisinin bir parçası olarak önemli bir yer kapsar (Barabási, 2002). ÇSA, genellikle bireyler veya gruplar (düğümler) ve bu düğümler arasındaki ilişkiler veya etkileşimlerden (kenarlardan) meydana gelen grafiksel yapılardır (Newman, 2003). Bu yapılar, sosyal ağların analizi için çeşitli modellerin yapı taşını oluşturur. Düğümler (Nodes), bireyleri veya kullanıcı hesaplarını temsil eder. Kenarlar (Edges) ise ilişkileri, arkadaşlıkları veya etkileşimleri ifade eder. Kenarlar, yönlü veya yönsüz olabilir.

ÇSA, bireylerden ve bu bireyler arasındaki ilişkilerden oluşan yapılardır. Bireyler insanlar, kuruluşlar, canlılar veya bilgi olabilmektedir. İlişkiler ise akrabalık, arkadaşlık, hayranlık, işbirliği, işlevsellik, kaynak aktarımı veya bilgi akışı, satın alma vb. olabilir. Sosyal ağların gelişmesiyle birlikte ağdaki düğümler ve ilişkiler hakkında bazı bilgilerin ortaya çıkarılmasına yönelik analiz çalışmaları ortaya çıkmıştır. Sosyal ağ analizi olarak

adlandırılan bu çalışmalarda elde edilecek bazı kriterler sayesinde genel olarak ağı yapı hakkında bilgi edinilebileceği gibi, ağıdaki herhangi bir unsur ve bu unsurun konumu ve ağı için önemi hakkında da bilgi sahibi olmak mümkündür. Çünkü sosyal ağı analizi, ağıda varolan aktörler arasındaki ilişkileri ve aktörlerin davranışlarını inceler. Sosyal ağların yapısını daha iyi anlamayı ve sosyal ağlarda saklı olan bilgileri ortaya çıkarmayı amaçlar.

Şekil 1.2.'de 2024 yılındaki en popüler çevrimiçi sosyal ağlar ve kullanıcı sayıları verilmiştir.



Şekil 1.2. 2024 yılındaki en popüler çevrimiçi sosyal ağlar ve kullanıcı sayıları

Yukarıda verilen Şekil 1.2.'yi ele aldığımızda 2024 yılındaki en popüler çevrimiçi sosyal ağı ve kullanıcı sayılarında en yüksek oran Facebook platformunda görülmüştür. Facebook'u en fazla kullanıcı sayısı ile takip eden platform ise YouTube olmuştur. Instagram ve WhatsApp platformları yaklaşık olarak aynı oranda kullanıcı sayısına sahip olmuştur. Diğer sosyal platformlar da azalan oranda kullanıcı sayısına sahip olmuştur. Kullanıcı sayıları milyarları bulan bu platformlar devasa bir iletişim ağı oluşturmaktadır.

1.3. Depresyon ve İntiharın Çevrimiçi Sosyal Ağlarda Tespiti

Depresyon ve intihar yönelimleri, kişilerin çevrimiçi paylaşımlarında çeşitli kullanımları aracılığıyla ortaya çıkabilir. Dil kullanımı, etkileşim biçimleri, paylaşım sıklığı ve görsel içerikler gibi çeşitli faktörler, bu tür yönelimlerin belirlenmesinde ciddi öneme sahiptir (Burnap ve ark., 2017). Örneğin, depresyon belirtileri olan bireylerin metinlerinde olumsuz duygu kelimeleri, düşük enerji modu ve karamsarlık ifadeleri daha sık görülür (Park ve ark., 2013). Benzer şekilde, intihar eğilimleri, sosyal medyada ümitsizlik, çaresizlik ve ölüm konulu paylaşımlarla kendini gösterebilir (O'Dea ve ark., 2015).

ÇSA, kişilerin günlük yaşamlarındaki duygusal durumlarını, düşüncelerini ve sosyal etkileşimlerini ifade ettikleri büyük platformlardır. Bu platformlarda kullanıcılar; video, metin ve görüntü gibi çeşitli formatlarda içerik paylaşmakta ve bu paylaşımlar, bireylerin ruh sağlığı hakkında önemli ipuçları verebilmektedir (Kumar ve ark., 2020). Son yıllarda, depresyon ve intihar benzeri önemli ruh sağlığı sorunlarının tespitinde ÇSA'dan elde edilen verilerin kullanımı artış göstermiştir. Bu bağlamda, derin öğrenme ve makine öğrenmesi yöntemleri, büyük oranda veriyle başa çıkma kapasitesi ve karmaşık ilişkileri öğrenme özellikleri sayesinde önemli bir rol oynamaktadır (De Choudhury ve ark., 2013). ÇSA'da depresyon ve intihar tespiti yapıldığı esnada bazı etik konulara da dikkat etmek gereklidir. İlk olarak, büyük ölçüde veriyle çalışmak, veri ve kullanıcı gizliliği yönünden kritik bir önem yaratmaktadır (Mittelstadt ve ark., 2016). Ayrıca, makine öğrenmesi modellerinin yanlış pozitif ve yanlış negatif sonuçlar yaratma olasılığı, yanlış alarm riskini artırabilir ve bu durum potansiyel olarak zararlı olabilir (Liu, 2020). Bu nedenle, bu tür sistemlerin geliştirilmesi ve uygulanması aşamasında etik prensiplere uyulması gerekmektedir. Ayrıca, Çoklu Modalite Veri Entegrasyonu da bu bağlamda önemli bir kavramdır. ÇSA'da depresyon ve intihar tespitinde, metin veya görüntü analizinden ziyade, farklı veri türlerinin entegrasyonu da önemlidir (Baltrušaitis ve ark., 2018). Derin öğrenme modelleri, bu tarz çeşitli verileri birlikte işleyerek, daha komplike ve gizli kalmış kalıpları öğrenebilir. Örneğin, DBN ve ANN, farklı veri kaynaklarından alınan bilgileri bir araya getirerek depresyon ve intihar tespitinde kullanılabilir (Bengio ve ark., 2007; LeCun ve ark., 2015).

ÇSA'da depresyon ve intihar tespiti farklı yöntemler kullanılarak yapılmaktadır. Aşağıda depresyon ve intihar tespiti için kullanılan Doğal Dil İşleme (NLP), Görüntü Analizi ve Duygu Analizi gibi yöntemlerden bahsedilmiştir.

- *NLP ve Metin Analizi*: Sosyal medya paylaşımlarındaki depresyon ve intihar belirtilerinin tespitinde en bilinen yöntemlerden biri, NLP teknikleri kullanarak metin analizidir. Makine öğrenmesi modelleri, büyük ölçüde metni işleyebilir ve bu metinlerdeki tahmini depresyon veya intihar risklerini tanımlayabilir (Guntuku ve ark., 2017). Örneğin, TF-IDF (Term Frequency-Inverse Document Frequency) gibi yöntemler, metindeki önemli anahtar kelimeleri belirlemek için kullanılabilirken (Sparck Jones, 1972), Word2Vec ve FastText gibi kelime gömme yöntemleri, kelimelerin anlamlarını ve yapılarını öğrenmek için kullanılır (Mikolov ve ark., 2013)(Bojanowski ve ark., 2017).
- *Görsel İçerik Analizi*: Sosyal medya platformlarındaki görsel içeriklerin analizi depresyon ve intihar tespiti için önemli bir veri kaynağıdır. CNN gibi derin öğrenme modelleri, görüntülerdeki renk, parlaklık, tema ve semboller gibi özellikleri analiz edip duygusal durumları belirleyebilmektedir (LeCun ve ark., 1998). Örneğin, koyu tonlar ve yalnızlık konulu görüntüler, depresyonun belirtileri olarak değerlendirilebilir (Reece ve ark., 2017).
- *Duygu Analizi ve Duygu Takibi*: Duygu analizi, bireylerin çevrimiçi paylaşımlarındaki duygusal hallerini tespit etmek için kullanılan önemli bir yöntemdir. Bu analizde, LSTM benzeri modeller, paylaşımların zamanla duygusal değişimlerini takip ederek depresyon veya intihar riski taşıyan kişileri tanımlayabilir (Hochreiter ve ark., 1997). LSTM, bilhassa sıralı veri üzerindeki bağımlılıkları öğrenmede başarılı olduğundan, bireylerin zaman içindeki duygusal değişimlerini anlamada önemli bir yöntemdir (Kim, 2014).

1.4. Literatür Taraması

Liu ve ark., (2019) tarafından yapılan çalışmada, intihara eğilimli bireylerin proaktif olarak belirlenmesini özel kriz yönetimiyle birleştiren sosyal medyaya dayalı yeni bir yaklaşım olan PSPO (Proactive Suicide Prevention Online) uygulanabilirliğini ve kabul edilebilirliğini test etmişlerdir. Burada kullandıkları yöntemlerde; İlk olarak çevrimiçi bir mikroblog grubu bulup, intihar notu hakkındaki yorumları uzmanlar tarafından analiz edilerek intihar tespitine yönelik makine öğrenimi modelleri için bir eğitim seti

sağlamışlardır. En iyi performans gösteren model, intihar düşünceleri ve davranışları öneren gönderileri otomatik olarak tanımlamak için kullanmışlardır. Ardından, model tarafından intihar riski altında olduğu belirlenen kullanıcılara intiharla ilgili konular, depresyon, yardım arama davranışı ve kabul edilebilirlik testini kapsayan önlemleri içeren kriz yönetimi bilgilerini içeren bir mikroblog doğrudan mesajı gönderilmiştir. Mesajı yanıtlayanlar için eğitilmiş danışmanlar özel kriz yönetimi sağlamıştır. Nisan 2017'de paylaşılmış toplam 27.007 yorum analiz edilmiştir. Bunlardan 2786'sı (%10,32) intihar düşünce ve davranışlarının göstergesi olarak sınıflandırılmıştır. Model yüksek kesinlik (.86), hassasiyet (.78), F-ölçümü (.86) ve doğruluk (.88) ile iyi bir performans göstermiştir. 3 Temmuz 2017 ile 3 Temmuz 2018 tarihleri arasında 12.486 sosyal medya kullanıcısına toplam 24.727 doğrudan mesaj gönderilip ve 5542'sine (%44,39) yanıt verilmiştir. İletişime geçilen kullanıcıların üçte birinden fazlası doğrudan mesajda yer alan anketleri doldurmuştur. Geçerli yanıtların %89,73'ü (1259/1403) intihar düşüncesi olduğunu, ancak yarısından fazlası (725/1403, %51,67) yardım istemediğini bildirmiştir. Hasta Sağlık Anketi-9 (PHQ-9) ortalama puanı 17.40 (SD 5.98) çıkmıştır. Katılımcıların üçte ikisinden fazlası (968/1403, %69.00) PSPO yaklaşımının kabul edilebilir olduğunu düşünmektedir. Ayrıca, 2321 kullanıcı doğrudan mesaja yanıt vermiştir. Konsültasyondan 1 ay önce ve sonra mikroblog gönderilerindeki kelime kullanım sıklığını karşılaştırdıklarında, ölüm odaklı kelimelerin sıklığının önemli ölçüde azaldığını, gelecek odaklı kelimelerin sıklığının ise önemli ölçüde arttığını tespit etmişlerdir.

Kumar ve ark., (2019) tarafından ele alınan çalışma da, sosyal medya platformlarındaki intihar eğilimlerini tespit etmek için NB ve SVM algoritmaları kullanılmıştır. Çalışma, özellikle sosyal medya kullanıcılarının dil ve duygusal tonlarındaki farklılıkları gözlemleyerek intihar riski taşıyan kişileri belirlemeyi amaçlamaktadır. Sonuçlar, SVM algoritmasının NB'e kıyasla daha yüksek doğruluğa sahip olduğunu göstermiştir. Bu başarı, SVM'in daha iyi bir ayrıştırma kapasitesine sahip olmasıyla ilişkilendirilmiştir. Ayrıca çalışma, sosyal medya verilerinin özellik seçiminde kullanılan yöntemlerin model performansı üzerindeki etkisini ele almıştır.

Lee ve ark., (2019) tarafından yapılan çalışmada, sosyal medya verilerinden depresyon ve intihar eğilimlerini tespit etmek için BERT (Bidirectional Encoder Representations from Transformers) tabanlı bir model geliştirilmiştir. BERT, sosyal medyada kullanılan doğal dili daha iyi anlamak ve yorumlamak için çift yönlü bir

bağlamdan faydalanmaktadır. Araştırmada, özellikle depresif odaklı mesajların doğru bir şekilde sınıflandırılabilmesi için derin öğrenme modellerinin etkisi incelenmiştir. BERT tabanlı modelin, geleneksel makine öğrenmesi yöntemlerine göre daha yüksek oranda doğruluğa sahip olduğu ve daha fazla bağlamsal bilgiyle çalıştığı vurgulanmıştır. Çalışmanın sonuçları, sosyal medya üzerindeki psikolojik sağlık belirtilerinin tespiti için BERT'in uygun bir model olduğunu göstermiştir.

Tadesse ve ark., (2019) çalışmalarında, Reddit kullanıcılarının gönderilerini inceleyerek ilgili çevrimiçi kullanıcıların depresyon tutumlarını ortaya çıkarabilecek faktörleri tespit etmeyi amaçlamışlardır. Bu amaçla, verileri eğitmek ve önerdikleri yöntemin verimliliğini değerlendirmek için NLP tekniklerini ve makine öğrenimi yaklaşımlarını kullanmışlardır. Depresyondaki hesaplar arasında daha yaygın olan terimlerden oluşan bir sözlük belirlemişlerdir. Sonuçlar, önerdikleri yöntemin performans doğruluğunu önemli ölçüde artırabileceğini göstermektedir. Çalışmaya göre en iyi yöntem, depresyonu %80 doğruluk ve %0,80 F1 puanı ile tespit eden SVM sınıflandırıcısı ile bigram olmuştur. Birleşik özelliklerin (LIWC + LDA + bigram) gücü ve etkinliği en başarılı şekilde Çok Katmanlı Algılayıcı (MLP) sınıflandırıcı ile gösterilmiş ve depresyon tespiti için %91 doğruluk ve %0,93 F1 puanına ulaşan en yüksek performans elde edilmiştir. Çalışmaya göre, uygun özellik seçimleri ve bunların çoklu özellik kombinasyonları ile daha iyi performans artışı elde edilebilir.

Patel ve ark., (2020) tarafından yapılan çalışma, sosyal medya paylaşımlarındaki depresyon belirtilerini tespit etmek amacıyla k-NN ve RF algoritmalarının performanslarını kıyaslamıştır. Çalışmada, depresyon belirtileri yer alan mesajların en doğru şekilde sınıflandırılabilmesi için duygu analizi teknikleri uygulanmıştır. Sonuçlar, RF algoritmasının depresyon belirtilerini daha yüksek doğrulukla tespit ettiğini ve sınıflandırma sürecinde daha etkili olduğunu göstermiştir. Çalışma, özellikle sosyal medya verilerinin büyük boyutlu ve düzensiz olması sebebiyle uygun algoritmaların seçiminin önemli olduğunu vurgulamaktadır.

Trifan ve ark., (2020) yaptıkları çalışma da, psikolinguistik kalıpların, depresif kullanıcıları çevrimiçi bir halka açık forumdaki yazılarına göre sınıflandırmak için standart bir makine öğrenimi yaklaşımı üzerindeki etkisini değerlendirmişlerdir. Psikolinguistik özellikleri kural tabanlı bir tahmin aracında birleştirilip ve bunların diğer üç standart sınıflandırıcıyla birlikte bu sınıflandırma sorunu üzerindeki etkilerini ele almışlardır.

Reddit Kendi Kendine Bildirilen Depresyon Teşhisi veri kümesindeki sonuçlar, aynı veri kümesi üzerinde daha önce bildirilen bazı çalışmalardan daha iyi performans göstermiştir. Kullandıkları veri kümesi, Ocak ve Ekim 2016 arasında gönderi paylaşan ve kendi kendine bildirilen teşhisin yüksek hassasiyetli kalıplarını eşleştiren tüm Reddit kullanıcılarından oluşmaktadır (örneğin, "Bana depresyon teşhisi kondu"). Depresyondaki kullanıcılar, ruh sağlığıyla ilgili bir alt dizinde hiç paylaşımda bulunmamış ve bununla ilgili bir terim kullanmamış kontrol kullanıcılarıyla eşleştirilmiştir. İki grubun doğrudan ayrılmasını önlemek için, teşhis konmuş kullanıcıların depresyon veya ruh sağlığıyla ilgili tüm paylaşımları çıkarılmıştır. Sonuç olarak, 9210 teşhis konmuş kullanıcı 107 274 kontrol kullanıcısıyla eşleştirilmiştir. Veri kümesindeki her kullanıcının ortalama 969 gönderisi vardır ve ortalama gönderi uzunluğu 148 belirteçtir. Veri kümesi başlangıçta, her biri kabaca 39.000 kullanıcının gönderilerini içeren benzer boyutta eğitim, doğrulama ve test örnekleri parçalarına bölünmüştür. Bu parçaların her birinin büyük boyutu (7 GB) nedeniyle, aşağıdaki üç sınıflandırıcı ile hem artımlı hem de çevrimiçi eğitimi araştırmışlardır: Multinomial Naive Bayes (MNB), Stokastik Gradyan İnişli (SGD) doğrusal ve Destek Vektör Makinesi ve Pasif Agresif (PA). Çekirdek dışı sınıflandırma için sınıflandırıcıları 500 kullanıcı verisinden oluşan gruplarla eğitmişlerdir. Parti büyüklüğünün sınıflandırıcıların performansı üzerinde bir etkisi olması beklenmemektedir. Bu sınıflandırıcıların her biri için, onları karakterize eden en iyi parametreleri belirlemek amacıyla doğrulama veri kümesi üzerinde bir ızgara araması gerçekleştirmişlerdir. İlk yaklaşım, metin sınıflandırması için standart bir işleme akışını takip etmiştir. Üç sınıflandırıcı için Kelime Torbası (BoW) özelliklerini dikkate alıp ve sayım ve TF-IDF tabanlı özellik ağırlıklandırması uygulamışlardır. Her bir modeli ayrı ayrı değerlendirmenin yanı sıra, PA sınıflandırıcı ile birlikte TF-IDF ve kural tabanlı tahmin edicinin çıktısı için eşit ağırlıklardan oluşan bir özellik birliğini değerlendirmişlerdir. Kesinlik açısından en iyi sonuçları PA sınıflandırıcı ile TF-IDF ağırlıklandırmasını kullanırken elde etmişlerdir.

Cheng ve ark., (2020) bu çalışma da, çevrimiçi platformlarda intihar eğilimlerinin tespiti amaçlı derin öğrenme ve makine öğrenmesi modellerinin karşılaştırılması yapılmıştır. Araştırmada, CNN ve SVM modelleri kullanılarak intihar riski taşıyan sosyal medya paylaşımlarının otomatik olarak sınıflandırılması hedeflenmiştir. CNN modeli, metinlerdeki detayları yakalama da yüksek performans göstermiştir. Sonuçlara göre, CNN'in özellikle kısa mesajlarda daha doğru sonuçlar ürettiği ve intihar eğilimindeki

kişileri tespit etmede SVM'ye oranla daha etkili olduğu görülmüştür. Bu çalışmada ayreten, model performansını artırmak için farklı özellik mühendisliği teknikleri ve ön işleme adımları kullanmıştır.

Mustafa ve ark., (2020) depresyonu teşhis etmenin tek yolunun kendi kendine raporlama olduğunu düşündüklerinden dolayı insanların duygularını ve günlük yaşam aktivitelerini paylaşmak için sosyal medyaya giderek daha fazla güveniyor olması ve bunun da ruh sağlıklarının tespit edilmesine yardımcı olduğuna kanaat getirmişlerdir. Çalışmaların da ,Twitter'dan depresyon bildiren ve tıbbi tedavi gören toplam 179 depresif birey seçmişlerdir. Bu kişilerin son tweetlerinin bir örneği kişi başına (200 ila 3200) tweet arasında toplamışlardır. Bu kişilerin tweetlerinden, TF-IDF kullanarak en sık kullanılan 100 kelimeyi seçmişlerdir. Daha sonra, bu kelimeleri duygulara göre sınıflandırmak için Dilbilimsel Sorgulama ve Kelime Sayımı'ndaki (LIWC) 14 psikolojik özniteliği kullanmışlardır. Ayrıca, LIWC tarafından sınıflandırıldıktan sonra her kelimeye mutludan mutsuza doğru ağırlıklar atayıp ve kullanıcıları depresyon Yüksek, Orta ve Düşük olmak üzere üç sınıfa ayırmak için makine öğrenimi sınıflandırıcılarını eğitmişlerdir. Yaptıkları çalışmaya göre, daha iyi özellik seçimleri ve bunların kombinasyonu, sınıflandırıcıların performansını ve doğruluğunu arttırmıştır.

Zhang ve ark., (2020) tarafından gerçekleştirilen çalışmada, sosyal medya mesajları üzerinden depresyon tespiti için RF ve SVM algoritmalarının performanslarını karşılaştırmayı amaçlamıştır. Araştırmada, depresyon konulu mesajların ayrıştırılması için çeşitli özellik mühendisliği teknikleri uygulanmış ve bu tekniklerin algoritmalar üzerindeki etkisi gözlemlenmiştir. Sonuçlara göre, RF algoritmasının, özellikle büyük veri kümelerinde yüksek başarı sağladığı ve daha yüksek doğruluk oranları elde ettiği tespit edilmiştir. Çalışma ayrıca, metinlerin sınıflandırılması sürecinde ele alınan duygu analizi yöntemlerinin depresyon belirtilerinin tespitinde önemli olduğunu belirtilmiştir.

Kim ve ark., (2021) çalışması, sosyal medya gönderilerindeki intihar eğilimlerini tespit etmek için CNN ve RNN (Recurrent Neural Network) modellerini karşılaştırmıştır. Çalışmada, CNN modelinin daha hızlı sonuç verdiği, fakat RNN modelinin intihar eğilimindeki mesajları daha doğru sınıflandırdığı saptanmıştır. Çalışma ayrıca, sosyal medya kullanıcılarının ruh sağlığına yönelik analizler yaparak toplumsal sağlık politikalarının iyileştirilmesine fayda sağlamayı hedeflemektedir.

Smith ve ark., (2021) çalışmalarında, sosyal medya ortamlarında elde edilen veriler üzerinde depresyon tespiti için derin öğrenme yöntemlerinin kullanımını incelemektedir. Bu çalışmada, özellikle LSTM ve GRU (Gated Recurrent Units) gibi en çok bilinen RNN modeli kullanılmıştır. Twitter ve Reddit gibi sosyal medya platformlarından alınan depresyon içerikli metinlerde yapılan analizler, LSTM modelinin GRU'ya oranla daha yüksek doğruluğa sahip olduğunu ortaya koymuştur. Bundan ziyade, çalışma verilerin dil işleme aşamasında NLP tekniklerini de kullanmıştır. Özellikle depresyon eğilimindeki kişilerin metinlerinde tekrar eden duygusal ve psikolojik konuların tespit edilmesi modelin başarı oranını artırmıştır. Çalışma, depresyon ve intihar eğilimini saptamak için derin öğrenme yöntemlerinin sosyal medya üzerinde etkili bir araç olduğunu göstermektedir.

Hassan ve ark., (2021) bu çalışmalarında, sosyal medya üzerindeki depresif mesajları tespit etmek için LSTM ve GRU modellerini karşılaştırmışlardır. Çalışmada, depresyon belirtisi taşıyan kişilerin sosyal medya paylaşımlarında belirli dil yapıları ve duygusal tonların kullanıldığı vurgulanmıştır. Analiz sonuçları, LSTM modelinin GRU'ya göre yüksek doğrulukla çalıştığını ve depresyon yönelimindeki mesajları daha iyi sınıflandırdığını göstermektedir. Ayrıca çalışma, dil işleme adımında uygulanan ön işleme basamaklarının model başarısını yükselttiğine dikkat çekmektedir.

Williams ve ark., (2021) çalışmalarında, sosyal medya platformlarında depresyonu tespit etmek amaçlı BERT tabanlı bir model geliştirmiştir. Çalışma, sosyal medya metinlerinde gizli depresyon belirtilerini tespit etmek için ileri düzey NLP tekniklerinin kullanılmasının önemini belirtmektedir. Özellikle BERT'in çift yönlü bağlamsal nitelikleri sayesinde depresyon eğilimindeki metinlerin doğru bir şekilde sınıflandırıldığı tespit edilmiştir. Bu çalışmada, sosyal medyanın modern toplulukta kişilerin ruh sağlığını etkileyen en önemli ortamlardan biri olduğu belirtilmiş ve BERT'in bu alandaki yüksek performansı öne çıkarılmıştır.

Angskun ve ark., (2022) tarafından yapılan çalışmada büyük veri analitiği kullanılarak sosyal ağlarda bir depresyon tespit modeli tanıtılmaktadır. Bu araştırmanın ana teorik çıkarımı, Twitter kullanıcılarının demografik özelliklerini ve metin duygularını analiz etmeye dayanan yeni bir modeldir. Modelin performansını artırmak için Varyans Analizi (ANOVA) SVM- Tekrarlayan Özellik Eleme (SVM-RFE) adı verilen iki özellik seçim yöntemi uygulanmıştır. Deneysel sonuçlar, ANOVA'nın daha yüksek bir f-ölçümü elde ettiğini ve SVM-RFE'den daha az işlem süresi tükettiğini ortaya koymuştur. Ardından,

depresyon tespit modeli inşası için makine öğrenimi teknikleri uygulanmıştır. Bu araştırmada SVM, Karar Ağacı, Naive Bayes, RF ve Derin Öğrenme olmak üzere beş makine öğrenimi tekniği incelenmiştir. Deneysel sonuçlar, RF tekniğinin depresyonu tespit etmek için diğer makine öğrenimi tekniklerinden daha yüksek doğruluk elde ettiğini ortaya koymuştur.

Malhotra ve Jindal (2022) yapmış oldukları çalışmada, yalnızca çevrimiçi sosyal ağ içeriğinden depresyon, kendine zarar verme ve intihar düşüncesinin erken tespiti ve klinik olmayan, öngörücü teşhisi için derin öğrenme tekniklerinin uygulamalarını incelemeyi amaçlamışlardır. Derin öğrenme tekniklerinin bu alandaki uygulamalarını inceleyen herhangi bir sistematik literatür taraması bulamamışlardır. Bu araştırma boşluğunu gidermek için, sosyal medya içeriğinden depresyon ve intihar veya kendine zarar verme davranışını tespit etmek için derin öğrenme tekniklerini uygulayan bugüne kadar yayınlanmış 96 ilgili araştırma çalışmasının sistematik bir literatür taramasını gerçekleştirmişlerdir. Yapılan çalışmanın sistematik literatür taraması sonucunda, bu 96 araştırma yayınının 59'u depresyonu, 16'sı kendine zarar vermeyi ve 34'ü intiharı tespit etmeye odaklanmıştır.

Renjith ve ark., (2022) Reddit sosyal medyasında intihar düşüncesinin tespiti görevinde metin sınıflandırmasının performansını artırmak için birleşik bir derin öğrenme sınıflandırıcısının bir uygulamasını oluşturmayı amaçlamışlardır. Yaptıkları çalışma da, altta yatan intihar niyetlerini tespit etmek amacıyla sosyal medya gönderilerini analiz etmek için bir LSTM-Attention-CNN kombine modelini kullanmışlardır. Çalışmanın değerlendirilmesi sonucunda, önerilen model %90,3'lük bir doğruluk ve %92,6'lık bir F1-skoru göstermiştir ki bu da karşılaştırılan modellerden daha yüksek çıkmıştır.

Lia ve ark., (2022) çalışmalarında, Twitter'daki kullanıcıların attığı tweetleri depresyonun tespit edilmesi amacıyla ele almışlardır. Depresyonda olan ve olmayan kullanıcıları ayırt etmek için Multinomial Naive Bayes, SVM, Karar Ağacı, RF, KNN ve LR makine öğrenimi yöntemlerini kullanmışlardır. Son olarak, SVM %79,90 doğruluk, %75,73 kesinlik, %77,53 hassasiyet ve %76,61 F1 sınıflandırma metrik sonuçları ile en iyi sonuca ulaşmıştır. Bu çalışmanın, kullanıcıların ruhsal durumlarının tespiti alanında akıllı sistemler geliştirenler için bir temel oluşturabileceğini düşünmüşlerdir.

Nguyen ve ark., (2022) tarafından yapılan çalışmada, sosyal medya platformlarındaki depresyon ve intihar eğilimlerini tespit etmek için CNN ve LSTM

modellerini karşılaştırmıştır. Bu araştırmada, sosyal medyada intihar riski taşıyan kişilerin dil yapılarını tespit etmek amaçlı duygu analizi yöntemleri de kullanılmıştır. LSTM modelinin en yüksek doğruluk oranına sahip olduğu bulunmuş, özellikle depresif mesajların sınıflandırılmasında daha başarılı olduğu belirtilmiştir. Çalışma da ayrıca, sosyal medya kullanıcılarının metinlerinde zamanla gözlemlenen değişikliklerin depresyon sinyalleri verdiği belirtmiştir.

1.5. Çalışma Hakkında

İnsanlar hayatlarının bir noktasında kendilerini umutsuz, üzgün ve çaresiz hissedebilirler ve bu normal durum zamanla oldukça tehlikeli bir hal alabilir. Birçok insan günlük yaşamlarında depresyon belirtileri gösterip bunlarla yaşamayı öğrenirken, daha kritik bir sorun olan 'intihar düşüncesi' devreye girebilir. Dünya genelindeki intihar oranları düşünüldüğünde bu çok ciddi bir sorundur. Bu sorunu tespit etmek ve çözmek için geleneksel yöntemlerin yanı sıra makine öğrenmesi ve derin öğrenme yöntemleri de kullanılmaktadır. Bu yöntemler çeşitli internet ortamlarından elde ettikleri verileri kullanarak insanların psikolojik durumları hakkında çıkarımlarda bulunabilirler. Son yıllarda oldukça popüler hale gelen Twitter, Facebook ve Instagram gibi çevrimiçi sosyal ağlar, depresyon ve intihar düşüncelerinin erken tespiti ve önlenmesi için oldukça faydalı ve geniş ölçekli bilgiler sağlamaktadır.

Bu çalışmada ÇSA gönderileri analiz edilerek geleneksel makine öğrenmesi ve derin öğrenme modelleri ile depresyon ve intihar tespiti amaçlanmıştır. Birçok başarılı model böylece karşılaştırılmış ve hangi modelin daha başarılı olduğu ortaya konulmuştur. Çalışmanın deneysel geçerliliğinin güçlü olması için Tweekter ve Reddit platformlarından elde edilen üç farklı veri seti kullanılmıştır. Bu verisetlerinde birçok model özellik seçme yöntemleri ile denenmiştir. Modellerin daha dengeli ve başarılı öğrenmelerini sağlamak için çapraz sorgulama (cross validation) yöntemi kullanılmıştır. Ayrıca her bir modelin hiperparametlerini optimize etmek için Gridsearch yöntemi de kullanılmıştır.

Tez kapsamında yapılan geniş deneysel çalışmalar sonucunda her bir veriseti için ayrı ayrı sonuçlar elde edilmiştir. Suicide Ideation Dataset veri setinde %94 doğruluk oranıyla RF yöntemi, Reddit Depression Suicidewatch veri setinde %73 doğruluk oranıyla LR modeli ve Suicide_Detection veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur. Grid Search yöntemi kullanılarak yapılan karşılaştırmalar sonucunda ise Suicide Ideation veri setinde %94 oranıyla RF modeli, Reddit Depression Suicidewatch

veri setinde %74 oranıyla ANN modeli ve Suicide Detection veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur.




2. MATERYAL VE METOT

Bu tez çalışmasında, farklı platformlardan ve kullanıcı kitlelerinden toplanan verilerden elde edilen veriler kullanılarak derin öğrenme ve makine öğrenmesi yöntemleri ile intihar tespiti gerçekleştirilmiştir.

2.1. Kullanılan Derin Öğrenme ve Makine Öğrenmesi Yöntemleri


Bu tez çalışmasında kullanılan derin öğrenme ve makine öğrenimi yöntemleri aşağıda kısaca açıklanmıştır.

FastText: Facebook tarafından geliştirilen bir metin sınıflandırma ve kelime temsil yöntemidir ve Word2Vec'in bir genişlemesidir. Bu model, kelimeleri alt parçalara (n-gramlar) ayırarak daha esnek ve anlamlı vektörler oluşturur. Özellikle zengin dillere sahip metinlerde yüksek performans göstermektedir. FastText, hızlı eğitimi ve düşük kaynaklı dillerdeki etkili performansı ile dikkat çeker (Bojanowski et al., 2017). Şekil 2.1'de FastText modeli gösterilmiştir.




Şekil 2.1. FastText Modeli

ANN: İnsan beyninin işleyişine benzer yapıda çalışan makine öğrenmesi algoritmalarıdır. ANN, çok katmanlı yapısı sayesinde karmaşık verilerdeki desenleri ve ilişkileri öğrenebilir. Eğitim esnasında, ağırlıklar yenilenerek belirli bir hata fonksiyonu minimize edilir. Görüntü işleme, ses tanıma ve NLP gibi çeşitli alanlarda yaygın olarak kullanılır (Goodfellow et al., 2016). Şekil 2.3'te bir ANN yapısı gösterilmiştir.




Şekil 2.2. Basit tekrarlayan sinir ağı yapısı

DBN: Katmanlı olarak eğitim alan ve derin öğrenme modelleri arasında yer alan bir yapıdır. DBN, her katmanın ayrı ayrı eğitimini gerçekleştiren, ardından bu katmanları birleştirerek bir bütün şeklinde ince ayar yapan bir yapıdır. Denetimsiz öğrenme ve denetimli öğrenme kombinasyonunu kullanarak daha komplike yapıların öğrenilmesine olanak tanır (Hinton et al., 2006). Şekil 2.3’te bir DBN yapısı gösterilmiştir.




Şekil 2.3. DBN mimarisi

CNN: Özellikle görüntü ve video işleme alanında yaygın olarak kullanılan bir derin öğrenme algoritmasıdır. Görüntü verisini işlemek için özel olarak tasarlanmış katmanlara (konvolüsyon katmanları) sahiptir. Bu katmanlar, görüntüdeki temel özellikleri ayrıştırarak ve bu özellikleri birleştirerek daha karmaşık yapıları öğrenir. Görsel tanıma ve sınıflandırma gibi işlevlerde yüksek performans gösterir (LeCun et al., 1998). Şekil 2.4’te kelime bazında sınıf tahmini yaparken kullanılan CNN çerçevesi gösterilmiştir.



Şekil 2.4. Kelime bazında sınıf tahmini yaparken kullanılan CNN çerçevesi

LSTM: Sıralı veriler üzerinde çalışan ve uzun vadeli bağımlılıkları öğrenebilen RNN modeli türüdür. RNN'lerin geleneksel unutma sorununa çözüm olarak geliştirilmiştir. Hatırlama hücreleri ve kapı mekanizmaları kullanarak eski bilgileri hafızaya alarak daha doğru tahminler yapar. LSTM, özellikle dil modeli, zaman serisi ve makine çevirisi tahmini gibi konularda etkin bir şekilde kullanılır (Hochreiter & Schmidhuber, 1997). Şekil 2.5'te temel LSTM mimarisi gösterilmiştir.




Forget Gate-Input Gate-Output Gate-Cell State

Şekil 2.5. Temel LSTM mimarisi


NB: Bu etkili yöntem, istatistik ilkelerine göre tanımlanmış bir çeşit hesaplama ile sisteme verilen verinin sınıfını bulmayı amaçlamaktadır. NB sınıflandırmasında sisteme belirli ölçüde eğitilmiş veri sunulur. Eğitilen veri sayısı ne kadar fazla olursa, test verisinin gerçek grubunu belirlemek o kadar kesinleşebilir. NB sınıflandırma yönteminin birden

fazla uygulaması bulunmaktadır (Reddy ve ark., 2022). Şekil 2.6 da NB algoritmasının temel olasılıksal yaklaşımı gösterilmiştir.



Şekil 2.6. NB yönteminin olasılıklar yaklaşımı


LR: Bu model, makine öğrenimi alanında önemli bir tekniktir. İki değişken arasındaki ilişkileri bulmak amacıyla matematiği kullanan bir veri analizi yöntemidir. Lojistik regresyon bu faktörlerden birinin değerini diğerine bağlı şekilde tahmin etmek için bu ilişkiyi kullanır. Tahmin genel olarak evet veya hayır gibi sınırlı sayıda sonuca sahiptir. Bu bilgiler, verimliliği artırmak, operasyonel maliyetleri azaltmak ve daha hızlı ölçeklendirmek için tahmine dayalı analiz için kullanılabilir (LaValley, 2008). Şekil 2.7’de bir LR’de yalnızca iki olası sonucun olduğu bir sınıflandırma örneği verilmiştir.



Şekil 2.7. Lojistik Regresyon ile sınıflandırma örneği


RF: Tek bir sonuca ulaşmak için bir karar ağacının çıktısını birleştiren ve yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. Kullanım kolaylığı ve esnekliği

sayesinde, sınıflandırma ve regresyon problemlerine benzediği için benimsenmesini hızlandırmıştır. Karar ağaçları popüler denetimli öğrenme algoritmaları olsa da, önyargı ve aşırı uyum gibi sorunlara yol açabilirler. Beraberinde, birden fazla karar ağacı rastgele orman algoritmasında bir topluluk oluşturduğunda, bilhassa bireysel ağaçlar korelasyonsuz olduğunda daha doğru sonuçlar tahmin ederler (Biau ve Scornet, 2016). Şekil 2.8’de RF algoritmasının basit gösterimi sunulmuştur.




Şekil 2.8. Random Forest

DT: Bu etkili yöntem, bir hedefe ulaşma istatistiği en yüksek olan bir stratejinin belirlenmesine yardımcı olmak için yöneylem araştırmasında, özellikle karar analizinde (Charbuty ve Abdulazeez, 2021) yaygın olarak kullanılmaktadır. Aynı zamanda makine öğreniminde de popüler bir araçtır. Bir karar ağacı, bir karar modeli ve şans olayı sonuçları, kaynak maliyetleri ve fayda dahil olmak üzere olası sonuçlarını kullanan hiyerarşik bir karar destek modelidir. Sadece şartlı kontrol ifadeleri içeren bir algoritmayı görselleştirmenin bir yoludur (Kotsiantis, 2013). Şekil 2.9’da DT algoritmasının basit işleyişi gösterilmiştir.



Şekil 2.9. Decision Tree

k-NN: Bu yöntem, bireysel bir veri noktasının gruplandırılmasında sınıflandırmalar veya tahminler yapmak amaçlı yakınlığı kullanan parametrik olmayan, denetimli bir öğrenme sınıflandırıcısıdır. Hem regresyon hem de sınıflandırma problemleri için kullanılabilmesine rağmen, klasik olarak benzer noktaların birbirine yakın bulunabileceği tahminiyle çalışan bir sınıflandırma algoritması olarak kullanılır (Cunningham and Delany, 2021). Şekil 2.10'da RF algoritmasının basit gösterimi sunulmuştur. Şekil 2.10'da k-NN algoritmasının basit gösterimi sunulmuştur.



Şekil 2.10. k-NN yöntemi

Grid Search: Grid Search, makine öğreniminde hiperparametre optimizasyonu için kullanılan sistematik bir arama yöntemidir. Bu teknik, belirlenen hiperparametrelerin farklı kombinasyonlarını test ederek en iyi modeli bulmaya yardımcı olur (Bergstra ve Bengio, 2012). Makine öğrenimi algoritmalarında hiperparametreler, modelin performansını

doğrudan etkileyen ayarlardır. Örneğin, bir SVM için C ve gamma parametreleri, yapay sinir ağları için öğrenme oranı ve katman sayısı hiperparametre olarak düşünülebilir (Hutter vd., 2019). Grid Search, belirlenen hiperparametre kombinasyonlarının her birini tek tek deneyerek modelin başarımını değerlendirir. Bu süreç zaman alıcı olsa da, küçük ve orta ölçekli veri setlerinde optimum sonuçlar verir (Pedregosa vd., 2011). Alternatif olarak Randomized Search yöntemi de kullanılabilir. Bu teknik, hiperparametreleri rastgele seçerek hesaplama süresini azaltırken iyi bir tahmin yapmaya çalışır (Bergstra vd., 2013).

2.2. Veri Seti

Bu tez çalışmasında, intihar eğilimlerini ve depresyon belirtilerini tespit etmeye yönelik üç farklı veri seti incelenmiştir. Her bir veri seti, farklı platformlardan ve kullanıcı kitlelerinden toplanan verilerle oluşturulmuş olup, bu konularda yapılan analizlere önemli katkılar sağlamaktadır.

İlk veri seti, Suicide Ideation Dataset adını taşımakta olup Twitter'dan elde edilen ve intihar eğilimlerini belirlemeye yönelik tweet'lerden oluşmaktadır. Bu veri seti, sosyal medya üzerinde intihar düşüncelerini tespit etmek için önemli bir kaynak olarak kabul edilmektedir. Veri setimiz toplam 1.778 satır veriden oluşmaktadır. Veri kümesinde 'Tweet' ve 'Suicide' olmak üzere iki sütun bulunmaktadır. Şekil 2.11'de Suicide Ideation veri setinden küçük bir örnek gösterilmiştir.

△ Tweet	△ Suicide
The "Tweet" column contains text content from Twitter, reflecting users' language, thoughts, emotions, and	"Potentially Suicidal" indicates distress/self-harm concerns, "Not Suicidal" signifies absence of such distress
1778 unique values	Not Suicide post 63% Potential Suicide ... 37%
making some lunch	Not Suicide post
@Alexia You want his money.	Not Suicide post
@dizzyhrvy that crap took me forever to put together. iâ m going to go sleep for DAYS	Potential Suicide post
@jnaylor #kiwitweets Hey Jer! Since when did you start twittering?	Not Suicide post

Şekil 2.11. Veri setindeki 'Tweet' ve 'Suicide' iki sütun sayısı

İkinci veri seti, Reddit platformunun "SuicideWatch" ve "depression" alt dizinlerinden gelen gönderilerin bir koleksiyonudur. Bu veri seti, Reddit'teki iki önemli topluluktan gelen kullanıcı verilerini içerir ve depresyon belirtilerinin yanı sıra intihar eğilimlerini tespit etmek için kullanılabilir. Veri setimiz toplam 20.346 satır veriden oluşmaktadır. Veri kümesinde 'text' ve 'label' olmak üzere iki sütun bulunmaktadır. Şekil 2.12'de Reddit Depression Suicidewatch verisetinden küçük bir örnek gösterilmiştir.

Δ text	Δ label
20346 unique values	depression 51% SuicideWatch 49%
I recently went through a breakup and she said she still wants to be friends so I said I can try doi...	depression
I do not know how to navigate these feelings, not that its a new feeling by any stretch. I just do n...	depression
So I have been with my bf for 5 months , and he already told me he was depressed. To this week nothi...	depression
I am so exhausted of this. Just when I think I can finally rest, just when I think maybe things are ...	SuicideWatch
I have been severly bullied since i was 5 till 15, this resulted in me being	depression

Şekil 2.12. Veri setindeki 'text' ve 'label' iki sütun sayısı

Son olarak, üçüncü veri seti ise, Suicide Detection başlığı altında sunulmuş ve intihar içerikli metinlerin tespitine yönelik hazırlanmıştır. Bu veri seti, Twitter üzerinden toplanan intihar içerikli gönderilerle ilgilidir ve özellikle sosyal medyada intihar eğilimlerini tespit etmeyi amaçlamaktadır. Veri setimiz toplam 232.074 satır veriden oluşmaktadır. Veri kümesinde 'text' ve 'class' olmak üzere iki sütun bulunmaktadır. Şekil 2.13'te Suicide Detection veri setinden küçük bir örnek gösterilmiştir. Her bir veri kümesi, intihar eğilimi ve depresyonun belirlenmesi için derin öğrenme ve makine öğrenmesi modelleri ile analiz edilebilecek geniş çaplı veriler sunmaktadır.


A text	A class
context extracted from user posts(input)	target variable
232074 unique values	2 unique values
Ex Wife Threatening SuicideRecently I left my wife for good because she has cheated on me twice and ...	suicide
Am I weird I don't get affected by compliments if it's coming from someone I know irl but I feel rea...	non-suicide
Finally 2020 is almost over... So I can never hear "2020 has been a bad year" ever again. I swear to...	non-suicide
i need helpjust help me im crying so hard	suicide

Şekil 2.13. Veri setindeki 'text' ve 'class' iki sütun sayısı

Her bir veri kümesi, intihar eğilimi ve depresyonun belirlenmesi için derin öğrenme ve makine öğrenmesi modelleri ile analiz edilebilecek geniş çaplı veriler sunmaktadır.

2.3. İntihar Tespiti Uygulama Adımları

Bu bölümde intihar tespit modelinin aşamaları açıklanmaktadır. Şekil 2.14'te uygulanan modellerin genel mimarisi verilmiştir.



Şekil 2.14. Uygulanan modellerin genel mimarisi

2.3.1. Veri ön işleme

Genel olarak yapılandırılmamış verilerin işlenmesi gerekmektedir. Yapılandırılmamış verilerden anlam çıkarmak için aşağıdaki işlemler gerçekleştirilerek veriler işlenebilir hale getirilmiştir.

Metin ön işleme, NLP süreçlerinde önemli bir aşamadır ve metinlerin analize uygun hale getirilmesi amacıyla çeşitli adımları içerir. Bu adımlardan ilki tokenizasyon işlemidir. Tokenizasyon, metnin belirli bir biçimde bölünerek dizilere veya kelime gruplarına ayrılması anlamına gelir. Bu işlem, metni daha küçük parçalara bölerek analiz edilebilir hale getirir. Örneğin, cümleler kelimelere veya kelimeler alt parçalara (n-gram) ayrılarak, dil modellemesi gibi çeşitli uygulamalar için sade hale getirilebilir.

Bir diğer adım ise **durdurma kelimelerini çıkarma** işlemidir. Durdurma kelimeleri, metin içinde sıklıkla kullanılan ve genellikle anlam katmayan kelimelerdir. "ve", "ile", "bir", "bu" gibi kelimeler bu gruba dahil edilir. Bu kelimelerin çıkarılması, metnin daha anlamlı bir şekilde analiz edilmesini sağlar ve yapılan işlemin süresini kısaltır.

Noktalama işaretlerinin ve rakamların çıkarılması, metin ön işleme aşamasının bir diğer adımıdır. Metindeki noktalama işaretleri ve sayılar, genel olarak metnin içeriği açısından anlam taşımaz. Bu sebeple, metnin daha sade hale getirilmesi için bu yapıların çıkarılması faydalı olur.

Normalleştirme adımı, metin içerisindeki büyük ve küçük harf ayrımının kaldırılması işlemidir. Normalleştirme, kelimelerin tutarlı bir şekilde ele alınmasını sağlar ve analizin daha kolay gerçekleştirilmesine olanak sağlar. Örneğin, "Veri" ve "veri" kelimeleri, normalleştirme işleminden sonra aynı biçimde değerlendirilir.

Son olarak, **stemming** işlemi, kelimelerdeki eklerin atılıp kelime köklerinin kaydedilmesi anlamını taşır. Stemming, kelimelerin kök yapılarını belirlemek için kullanılır ve dil işleme sistemlerinin daha az değişkenle ilgilenmesine olanak tanır. Örneğin, "görmek", "gördü" ve "görme" gibi kelimeler, "gör" köküne indirgenebilir. Bu işlem, metinlerin analiz aşamasında önemli bir rol oynar. Bunun nedeni, kelimelerin anlamlarını birleştirerek, veri setinin boyutunu küçültmek ve modelin genel başarısını arttırmaktır (Abu ve ark., 2019).

2.3.2. Verilerin vektörleştirilmesi

Bu adımda, metin ön işleme adımından sonra elde edilen özellikler vektör formunda ifade edilir. Verilerin vektörleştirilmesi, NLP alanında metinlerin dijital biçimlere dönüştürülmesi için kullanılan kök ifadedir. Bu dönüşüm, bilgisayarların metinleri anlamasına ve işlemesine olanak tanır. Vektörleştirme işlemi, metinlerin kelimelerinin temsillerini içerir. Yaygın örneklerden biri olan BoW, metindeki kelimelerin frekanslarını söyleyerek bir kelime torbası oluşturur. Diğer bir yöntem olan TF-IDF, belirli bir şeyin belirli bir belgede ne kadar sık geçtiği ve bu merkezi veri kurulumundaki yaygınlığını değerlendirerek daha anlamlı bir ifade sunar. Ayreten, "Word Embedding" teknikleri, kelimelerin yoğun vektörler olarak temsil edilmesini sağlar ve kelimeler arasındaki anlam akışını daha etkili bir biçimde yansıtır. Bu şifreleme, metinlerin daha fazla ayrıntı analizinin yapılması ve makine işlemlerinin uygulanmasının gerçekleştirilmesini sağlar (Bengio ve ark., 2013).

2.3.3. Özellik ölçeklendirme


Veri setindeki iki farklı özelliğin sahip olduğu değerlerin en doğru şekilde analiz edilmesini sağlayan bir yöntemdir.

Bu yöntem, makine öğrenimi modellerinde önemli bir veri ön işleme adımıdır. Farklı ölçeklere sahip özelliklerin doğru ve anlamlı bir şekilde kıyaslanabilmesi için bu yöntemler kullanılır. Ölçeklendirme işlemi, özellikle mesafeye dayalı algoritmalar ve gradyan tabanlı optimizasyon yöntemleri için önemlidir. En yaygın iki ölçeklendirme tekniği 'standardizasyon' ve 'min-maks normalizasyonu'dur. Standardizasyon tekniğinde, veriler ortalaması sıfır ve standart sapması bir olacak şekilde yeniden ölçeklendirilir, bu da verilerin merkezi dağılımını ve varyansını kontrol etmeye olanak sağlar. Min-maks normalizasyon tekniği ise, verileri belirli bir aralığa (genellikle 0 ile 1 arasında) dönüştürerek özelliklerin tahmini dağılımını korur. Özellik ölçeklendirme, makine öğrenimi algoritmalarının daha hızlı ve etkili şekilde öğrenmesini sağlayarak model doğruluğunu artırır. Bu adımların doğru uygulanması, karmaşık veri kümelerinde performansı önemli oranda artırabilir (URL-10) .

2.4. Derin Öğrenme Modellerinin Hiperparametreleri

Derin öğrenme modellerinin hiperparametreleri, modelin öğrenme sürecini etkileyen ve sonuçları belirleyen önemli ayarlardır. Bu hiperparametreler içerisinde

öğrenme oranı, epoch sayısı, batch boyutu, ağ yapısı, aktivasyon fonksiyonları ve düzenleme teknikleri yer almaktadır. (Chollet, 2017; Goodfellow et al., 2016). 2.15’te derin öğrenme uygulamalarında parametre ve hiperparametre işleyiş yapısı sunulmuştur.



Şekil 2.15. Derin öğrenme uygulamalarında parametre ve hiperparametre


Öğrenme Oranı: Modelin ağırlıklarının her güncelleme adımında ne kadar değiştirileceğini belirler. Düşük öğrenme oranları daha güvenli olup, yavaş bir öğrenme süreci sağlar. Yüksek öğrenme oranları ise hızlı öğrenme sağlayabilir fakat aşırıya kaçma riski taşır (Chollet, 2017).

Epoch Sayısı: Tüm eğitim verisi üzerinde modelin kaç kez çalışacağını belirtir. Çok fazla epoch kullanmak, aşırı öğrenmeye (overfitting) yol açabilir (Goodfellow, Bengio, & Courville, 2016).

Batch Boyutu: Modelin güncellenmesi için kullanılan örnek sayısını belirtir. Küçük batch boyutları, daha sık güncellemeler elde ederken; büyük batch boyutları daha az güncellemeyle daha sabit bir süreç sunabilir (Brownlee, 2020).

Ağ Yapısı (Network Architecture): Katman sayısı, her katmandaki nöron sayısı ve katman çeşitleri gibi ağın mimari yapılarıdır. Derin ve geniş ağlar daha karmaşık ilişkileri öğrenebilir (Chollet, 2017).

Aktivasyon Fonksiyonları: Nöronların çıkışlarını belirlemek amaçlı kullanılan fonksiyonlardır. ReLU, sigmoid, tanh gibi çeşitli aktivasyon fonksiyonları, modelin öğrenme becerisini etkileyebilir (Goodfellow, Bengio, & Courville, 2016). Şekil 2.16’da en popüler aktivasyon fonksiyonlarının grafikleri verilmiştir.



Şekil 2.16. En popüler aktivasyon fonksiyonlarının grafikleri

Düzenleme Teknikleri: Aşırı öğrenmeyi önlemek amaçlı kullanılan yöntemlerdir. Dropout, L1 ve L2 düzenlemeleri, modelin genelleme yapma yeteneğini artırır (Brownlee, 2020).

2.5. Sınıflandırma Performans Metrikleri

Tez çalışmamızda kullandığımız metrikler, bir modelin doğruluğunu ve genel performansını ölçmek amacıyla kullanılmaktadır. Bu metrikler hakkında aşağıda detaylı açıklamalar ve formülleri verilmiştir.

Doğruluk (Accuracy) : Modelin doğru tahminlerinin toplam tahminlere oranını vermektedir. Bu metrik, sınıfların dengesiz veri kümelerinde yanıltıcı olmakla beraber dengeli veri kümelerinde iyi çalışır.

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (2.1)$$

Kesinlik (Precision) : Modelin pozitif tahminlerinin ne oranda doğru olduğunu ölçmektedir. Yüksek oranlı kesinlik, yanlış pozitiflerin az olduğu anlamına gelmektedir, bu şekilde özellikle yanlış pozitiflerin maliyetli olduğu durumlarda önem taşımaktadır.

$$Precision = \frac{TP}{TP+FP} \quad (2.2)$$

Hassasiyet (Recall) : Modelin gerçek pozitifleri ne derece iyi tanımlayabildiğini göstermektedir. Bu metrik, özellikle kaçırılan pozitiflerin maliyetli olduğu durumlarda önem taşımaktadır.

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

F1-Skor (F1-Score) : Kesinlik ve duyarlılığı dengeleyen harmonik ortalamayı göstermektedir. Bu metrik, dengesiz olan veri kümelerinde performansı daha iyi ölçmektedir.

$$F - 1 \text{ score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4)$$

2.6. Deneysel Sonuçlar

Bu çalışmada, ANN, DBN, CNN, LTSM, k-NN, DT, RF, LR ve NB modelleri doğruluk, kesinlik, hassasiyet ve F-skor metrikleri kullanılarak karşılaştırılmıştır. Bu karşılaştırmalara ek olarak FastText yöntemiyle elde edilen kelime gömme (word embedding) vektörleri derin öğrenme modellerine girdi olarak verilmiş ve sonuçlar karşılaştırılmıştır. Ayrıca tüm modeller için önce Gridsearch yöntemi kullanılmadan sonuç alınmış ve daha sonra Gridsearch kullanılarak sonuçlar alınmıştır. Böylece Gridsearch ile gerçekleşen iyileştirmeler gözlemlenmiştir. Veri setleri için %60 train %40 test, %80 train ve %20 test oranları denenmiştir. En iyi sonuçlar %80 train ve %20 test değerleri ile elde edilmiştir. Tüm modellerde çapraz sorgulama (cross validation) uygulanmıştır.

2.6.1. Suicide ideation veri seti için makine öğrenmesi modellerinin sonuçları

Tablo 2.1 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.1. LR'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	215	43
	İntihar Değil	1	98

Tablo 2.1'de gösterildiği gibi, LR algoritması toplam 357 tweetten 313 tweeti doğru sınıflandırmış ve 44 tweeti yanlış sınıflandırmıştır. LR için TP 215, FP 43, FN 1 ve TN 98'dir.

Tablo 2.2 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.2. NB'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	172	5
	İntihar Değil	39	140

Tablo 2.2'de gösterildiği gibi, NB algoritması toplam 356 tweetten 312 tweeti doğru sınıflandırmış ve 44 tweeti yanlış sınıflandırmıştır. NB için TP 172, FP 5, FN 39 ve TN 140'dır.

Tablo 2.3 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.3. RF'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	317	22
	İntihar Değil	10	185

Tablo 2.3'te gösterildiği gibi, RF algoritması toplam 534 tweetten 502 tweeti doğru sınıflandırmış ve 32 tweeti yanlış sınıflandırmıştır. RF için TP 317, FP 22, FN 10 ve TN 185'dir.

Tablo 2.4 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.4. DT'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	297	25
	İntihar Değil	30	182

Tablo 2.4'te gösterildiği gibi, DT algoritması toplam 534 tweetten 479 tweeti doğru sınıflandırmış ve 55 tweeti yanlış sınıflandırmıştır. DT için TP 297, FP 25, FN 30 ve TN 182'dir.

Tablo 2.5 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.5. KNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	211	94
	İntihar Değil	0	51

Tablo 2.5'de gösterildiği gibi, KNN algoritması toplam 356 tweetten 262 tweeti doğru sınıflandırmış ve 94 tweeti yanlış sınıflandırmıştır. KNN için TP 211, FP 94, FN 0 ve TN 51'dir.

2.6.2. Suicide Ideation veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları


Tablo 2.6 FastText için ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.6. FastText için ANN'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	209	145
	İntihar Değil	2	0

Tablo 2.6'da gösterildiği gibi, ANN algoritması toplam 356 tweetten 209 tweeti doğru sınıflandırmış ve 147 tweeti yanlış sınıflandırmıştır. ANN için TP 209, FP 145, FN 2 ve TN 0'dır.

Şekil 2.17'de ANN algoritmasının train loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.17. ANN için train loss ve validation accuracy grafikleri


Tablo 2.7 FastText için LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.7. FastText için LSTM'in karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	196	23
İntihar Değil	15	122

Tablo 2.7'de gösterildiği gibi, LSTM algoritması toplam 356 tweetten 318 tweeti doğru sınıflandırmış ve 38 tweeti yanlış sınıflandırmıştır. LSTM için TP 196, FP 23, FN 15 ve TN 122'dir.

Şekil 2.18'de LSTM algoritmasının validation loss ve validation accuracy grafiklerini göstermiştir.

**Şekil 2.18.** LSTM için validation loss ve validation accuracy grafikleri


Tablo 2.8 FastText için DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.8. FastText için DBN'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	175	32
İntihar Değil	36	113

Tablo 2.8'de gösterildiği gibi, DBN algoritması toplam 356 tweetten 288 tweeti doğru sınıflandırmış ve 68 tweeti yanlış sınıflandırmıştır. DBN için TP 175, FP 32, FN 36 ve TN 113'tür.

Şekil 2.19'da DBN algoritmasının training accuracy ve testing accuracy grafiklerini göstermiştir.



Şekil 2.19. DBN için training accuracy ve testing accuracy grafikleri


Tablo 2.9 FastText için CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.9. FastText için CNN'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	185	76
	İntihar Değil	26	69

Tablo 2.9'da gösterildiği gibi, CNN algoritması toplam 356 tweetten 254 tweeti doğru sınıflandırmış ve 102 tweeti yanlış sınıflandırmıştır. CNN için TP 185, FP 76, FN 26 ve TN 69'dur.

Şekil 2.20'de CNN algoritmasının validation accuracy ve validation loss grafiklerini göstermiştir.



Şekil 2.20. CNN için validation accuracy ve validation loss grafikleri

2.6.3. Reddit Depression Suicidewatch veri seti için makine öğrenmesi modellerinin sonuçları

Tablo 2.10 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.10. LR'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1426	516
	İntihar Değil	567	1564

Tablo 2.10'da gösterildiği gibi, LR algoritması toplam 4073 tweetten 2990 tweeti doğru sınıflandırmış ve 1083 tweeti yanlış sınıflandırmıştır. LR için TP 1426, FP 516, FN 567 ve TN 1564'tür.

Tablo 2.11 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.11. NB'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1562	634
	İntihar Değil	476	1399

Tablo 2.11'de gösterildiği gibi, NB algoritması toplam 8142 tweetten 2961 tweeti doğru sınıflandırmış ve 1110 tweeti yanlış sınıflandırmıştır. NB için TP 1562, FP 634, FN 476 ve TN 1399'dur.

Tablo 2.12 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.12. RF'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	2113	788
	İntihar Değil	921	2285

Tablo 2.12'de gösterildiği gibi, RF algoritması toplam 6107 tweetten 4398 tweeti doğru sınıflandırmış ve 1709 tweeti yanlış sınıflandırmıştır. RF için TP 2113, FP 788, FN 921 ve TN 2285'tir.

Tablo 2.13 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.13. DT'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	1942	1119
	İntihar Değil	1092	1954

Tablo 2.13'te gösterildiği gibi, DT algoritması toplam 6107 tweetten 3896 tweeti doğru sınıflandırmış ve 2211 tweeti yanlış sınıflandırmıştır. DT için TP 1942, FP 1119, FN 1092 ve TN 1954'tür.

Tablo 2.14 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.14. KNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	1548	1167
	İntihar Değil	490	866

Tablo 2.14'te gösterildiği gibi, KNN algoritması toplam 4071 tweetten 2414 tweeti doğru sınıflandırmış ve 1657 tweeti yanlış sınıflandırmıştır. KNN için TP 1548, FP 1167, FN 490 ve TN 866'dır.

2.6.4. Reddit Depression Suicidewatch veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları

Tablo 2.15 FastText için ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.15. FastText için ANN'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	1381	565
İntihar Değil	657	1468

Tablo 2.15'de gösterildiği gibi, ANN algoritması toplam 4071 tweetten 2849 tweeti doğru sınıflandırmış ve 1222 tweeti yanlış sınıflandırmıştır. ANN için TP 1381, FP 565, FN 657 ve TN 1468'dir.

Şekil 2.21'de ANN algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.



Şekil 2.21. ANN için training accuracy ve test accuracy grafikleri


Tablo 2.16 FastText için LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.16. FastText için LSTM'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1334	480
	İntihar Değil	704	1553

Tablo 2.16'da gösterildiği gibi, LSTM algoritması toplam 4071 tweetten 2887 tweeti doğru sınıflandırmış ve 1184 tweeti yanlış sınıflandırmıştır. LSTM için TP 1334, FP 480, FN 704 ve TN 1553'tür.

Şekil 2.22'de LSTM algoritmasının training loss ve training accuracy grafiklerini göstermiştir.

**Şekil 2.22.** LSTM için training loss ve training accuracy grafikleri

Tablo 2.17 FastText için DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.17. FastText için DBN'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1187	796
	İntihar Değil	851	1237

Tablo 2.17'de gösterildiği gibi, DBN algoritması toplam 4071 tweetten 2424 tweeti doğru sınıflandırmış ve 1647 tweeti yanlış sınıflandırmıştır. DBN için TP 1187, FP 796, FN 851 ve TN 1237'dir.

Şekil 2.23'te DBN algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.



Şekil 2.23. DBN training validation ve test validation grafikleri


Tablo 2.18 FastText için CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.18. FastText için CNN'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1449	615
	İntihar Değil	589	1418

Tablo 2.18'de gösterildiği gibi, CNN algoritması toplam 4071 tweetten 2867 tweeti doğru sınıflandırmış ve 1204 tweeti yanlış sınıflandırmıştır. CNN için TP 1449, FP 615, FN 589 ve TN 1418'dir.

Şekil 2.24'te CNN algoritmasının training accuracy ve training loss grafiklerini göstermiştir.



Şekil 2.24. CNN için training accuracy ve training loss grafikleri

2.6.5. Suicide Detection veri seti için makine öğrenmesi modellerinin sonuçları

Tablo 2.19 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.19. LR'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	21924	1784
	İntihar Değil	1363	21344

Tablo 2.19'da gösterildiği gibi, LR algoritması toplam 46415 tweetten 43268 tweeti doğru sınıflandırmış ve 3147 tweeti yanlış sınıflandırmıştır. LR için TP 21924, FP 1784, FN 1363 ve TN 21344'tür.

Tablo 2.20 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.20. NB'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	19344	1097
	İntihar Değil	3943	22031

Tablo 2.20'de gösterildiği gibi, LR algoritması toplam 46415 tweetten 43268 tweeti doğru sınıflandırmış ve 3147 tweeti yanlış sınıflandırmıştır. LR için TP 21924, FP 1784, FN 1363 ve TN 21344'tür.

Tablo 2.21 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.21. RF'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
	İntihar	İntihar Değil
İntihar	31630	6771
İntihar Değil	3194	28028

Tablo 2.21'de gösterildiği gibi, RF algoritması toplam 69623 tweetten 59658 tweeti doğru sınıflandırmış ve 9965 tweeti yanlış sınıflandırmıştır. RF için TP 31630, FP 6771, FN 3194 ve TN 28028'dir.

Tablo 2.22 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.22. DT'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
	İntihar	İntihar Değil
İntihar	28782	5002
İntihar Değil	6042	29797

Tablo 2.22'de gösterildiği gibi, DT algoritması toplam 69623 tweetten 58579 tweeti doğru sınıflandırmış ve 11044 tweeti yanlış sınıflandırmıştır. DT için TP 28782, FP 5002, FN 6042 ve TN 29797'dir.

Tablo 2.23 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.23. KNN'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
	İntihar	İntihar Değil
İntihar	20728	6398
İntihar Değil	2559	16730

Tablo 2.23'te gösterildiği gibi, KNN algoritması toplam 46415 tweetten 37458 tweeti doğru sınıflandırmış ve 8957 tweeti yanlış sınıflandırmıştır. KNN için TP 20728, FP 6398, FN 2559 ve TN 16730'dur.

2.6.6. Suicide Detection veri seti için fasttext uygulanan derin öğrenme modellerinin sonuçları


Tablo 2.24 FastText için CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.24. FastText için CNN'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	2159	139
	İntihar Değil	246	2098

Tablo 2.24'te gösterildiği gibi, CNN algoritması toplam 4642 tweetten 4257 tweeti doğru sınıflandırmış ve 385 tweeti yanlış sınıflandırmıştır. CNN için TP 2159, FP 139, FN 246 ve TN 2098'dir.

Şekil 2.25'te CNN algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.



Şekil 2.25. CNN için training accuracy ve training loss grafikleri


Tablo 2.25 FastText için LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.25. FastText için LSTM'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	2405	2237
	İntihar Değil	0	0

Tablo 2.25'te gösterildiği gibi, LSTM algoritması toplam 4642 tweetten 2405 tweeti doğru sınıflandırmış ve 2237 tweeti yanlış sınıflandırmıştır. LSTM için TP 2405, FP 2237, FN 0 ve TN 0'dır.

Şekil 2.26'da LSTM algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.

**Şekil 2.26.** LSTM için training accuracy ve training accuracy grafikleri


Tablo 2.26 FastText için DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.26. FastText için DBN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	18313	1880
	İntihar Değil	4974	21248

Tablo 2.26'da gösterildiği gibi, DBN algoritması toplam 46415 tweetten 39561 tweeti doğru sınıflandırmış ve 6854 tweeti yanlış sınıflandırmıştır. DBN için TP 18313, FP 1880, FN 4974 ve TN 21248'dir.

Şekil 2.27'de DBN algoritmasının training loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.27. DBN için training loss ve validation accuracy grafikleri


Tablo 2.27 FastText için ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.27. FastText için ANN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	10928	684
	İntihar Değil	747	10849

Tablo 2.27'de gösterildiği gibi, ANN algoritması toplam 23208 tweetten 21777 tweeti doğru sınıflandırmış ve 1431 tweeti yanlış sınıflandırmıştır. ANN için TP 10928, FP 684, FN 747 ve TN 10849'dur.

Şekil 2.28'de ANN algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.



Şekil 2.28. ANN için training accuracy ve test accuracy grafikleri

2.6.7. İncelenen üç veri setinin karşılaştırmalı sonuçları

Tablo 2.28 Suicide Ideation veri seti için yöntemlerin metriklere göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.28. Suicide Ideation veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
FastText-CNN	0.71	0.71	0.88	0.78
FastText-LSTM	0.89	0.89	0.93	0.91
FastText-DBN	0.80	0.85	0.83	0.84
FastText-ANN	0.58	0.59	0.99	0.74
Lojistik Regresyon	0.87	0.83	1.00	0.91
Naive Bayes	0.87	0.97	0.82	0.89
Random Forest	0.94	0.94	0.97	0.95
Decision Tree	0.89	0.92	0.91	0.92
KNN	0.73	0.69	1.00	0.82

Tablo 2.28'deki sonuçlara göre, RF yöntemi Doğruluk, F-Skoru metriklerinde en iyi sonucu almıştır. LR ve KNN yöntemleri Hassasiyet metriğinde en iyi sonucu almış, Kesinlik metriğinde ise NB yöntemi en iyi sonucu almıştır

Tablo 2.29 Reddit Depression Suicidewatch veri seti için yöntemlerin metriklere göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.29. Reddit Depression Suicidewatch veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
FastText-CNN	0.70	0.70	0.71	0.71
FastText-LSTM	0.70	0.74	0.65	0.69
FastText-DBN	0.59	0.60	0.58	0.59
FastText-ANN	0.69	0.71	0.68	0.69
Lojistik Regresyon	0.73	0.73	0.72	0.72
Naive Bayes	0.72	0.71	0.77	0.74
Random Forest	0.72	0.73	0.70	0.71
Decision Tree	0.63	0.63	0.64	0.64
KNN	0.59	0.57	0.76	0.65

Tablo 2.29'daki sonuçlara göre, LR yöntemi Doğruluk metriğinde en iyi sonucu almıştır. NB yöntemi Hassasiyet ve F-Skoru metriklerinde en iyi sonucu almış, Kesinlik metriğinde ise LSTM yöntemi en iyi sonucu almıştır.

Tablo 2.30 Suicide Detection veri seti için yöntemlerin metriklere göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.30. Suicide Detection veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
FastText-CNN	0.91	0.94	0.90	0.92
FastText-LSTM	0.51	0.52	1.00	0.68
FastText-DBN	0.85	0.91	0.79	0.84
FastText-ANN	0.93	0.94	0.94	0.94
Lojistik Regresyon	0.93	0.92	0.94	0.93
Naive Bayes	0.89	0.95	0.83	0.88
Random Forest	0.85	0.82	0.91	0.86
Decision Tree	0.84	0.85	0.83	0.84
KNN	0.80	0.76	0.89	0.82

Tablo 2.30'daki sonuçlara göre, LR ve ANN yöntemleri Doğruluk metriğinde en iyi sonucu almıştır. LSTM yöntemi Hassasiyet, ANN yöntemi F-Skoru metriğinde, NB yöntemi ise Kesinlik metriğinde en iyi sonuçları almıştır.

2.6.8. Suicide Ideation veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları

Tablo 2.31 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.31. LR'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	210	17
	İntihar Değil	6	124

Tablo 2.31'de gösterildiği gibi, LR algoritması toplam 357 tweetten 334 tweeti doğru sınıflandırmış ve 23 tweeti yanlış sınıflandırmıştır. LR için TP 210, FP 17, FN 6 ve TN 124'tür.

Tablo 2.32 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.32. NB'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	173	5
	İntihar Değil	38	140

Tablo 2.32'de gösterildiği gibi, NB algoritması toplam 356 tweetten 313 tweeti doğru sınıflandırmış ve 43 tweeti yanlış sınıflandırmıştır. NB için TP 173, FP 5, FN 38 ve TN 140'dır.

Tablo 2.33 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.33. RF'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	316	21
	İntihar Değil	11	186

Tablo 2.33'de gösterildiği gibi, RF algoritması toplam 534 tweetten 502 tweeti doğru sınıflandırmış ve 32 tweeti yanlış sınıflandırmıştır. RF için TP 316, FP 21, FN 11 ve TN 186'dır.

Tablo 2.34 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.34. DT'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	301	27
	İntihar Değil	26	180

Tablo 2.34'te gösterildiği gibi, DT algoritması toplam 534 tweetten 481 tweeti doğru sınıflandırmış ve 53 tweeti yanlış sınıflandırmıştır. DT için TP 301, FP 27, FN 26 ve TN 180'dir.

Tablo 2.35 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.35. KNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	211	84
	İntihar Değil	0	61

Tablo 2.35'te gösterildiği gibi, KNN algoritması toplam 356 tweetten 272 tweeti doğru sınıflandırmış ve 84 tweeti yanlış sınıflandırmıştır. KNN için TP 211, FP 84, FN 0 ve TN 61'dir.

2.5.9. Suicide Ideation veri seti için grid search uygulanan derin öğrenme modellerinin sonuçları


Tablo 2.36 ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.36. ANN'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	211	145
İntihar Değil	0	0

Tablo 2.36'da gösterildiği gibi, ANN algoritması toplam 356 tweetten 211 tweeti doğru sınıflandırmış ve 145 tweeti yanlış sınıflandırmıştır. ANN için TP 211, FP 145, FN 0 ve TN 0'dır.

Şekil 2.29'da ANN algoritmasının training loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.29. ANN için training loss ve validation accuracy grafikleri


Tablo 2.37 LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.37. LSTM'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	196	15
İntihar Değil	15	130

Tablo 2.37'de gösterildiği gibi, LSTM algoritması toplam 356 tweetten 326 tweeti doğru sınıflandırmış ve 30 tweeti yanlış sınıflandırmıştır. LSTM için TP 196, FP 15, FN 15 ve TN 130'dur.

Şekil 2.30'da LSTM algoritmasının training loss ve training accuracy grafiklerini göstermiştir.



Şekil 2.30. LSTM için training loss ve training accuracy grafikleri

Tablo 2.38 DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.38. DBN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	186	29
	İntihar Değil	25	116

Tablo 2.38'de gösterildiği gibi, DBN algoritması toplam 356 tweetten 302 tweeti doğru sınıflandırmış ve 54 tweeti yanlış sınıflandırmıştır. DBN için TP 186, FP 29, FN 25 ve TN 116'dır.

Şekil 2.31'de DBN algoritmasının training accuracy ve testing accuracy grafiklerini göstermiştir.



Şekil 2.31. DBN için training accuracy ve testing accuracy grafikleri


Tablo 2.39 CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.39. CNN'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	185	74
	İntihar Değil	26	71

Tablo 2.39'da gösterildiği gibi, CNN algoritması toplam 356 tweetten 256 tweeti doğru sınıflandırmış ve 100 tweeti yanlış sınıflandırmıştır. CNN için TP 185, FP 74, FN 26 ve TN 71'dir.

Şekil 2.32'de CNN algoritmasının training accuracy ve training loss grafiklerini göstermiştir.



Şekil 2.32. CNN için training accuracy ve training loss grafikleri

2.6.10. Reddit Depression Suicidewatch veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları

Tablo 2.40 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.40. LR'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1415	511
	İntihar Değil	578	1569

Tablo 2.40'da gösterildiği gibi, LR algoritması toplam 4073 tweetten 2984 tweeti doğru sınıflandırmış ve 1089 tweeti yanlış sınıflandırmıştır. LR için TP 1415, FP 511, FN 578 ve TN 1569'dur.

Tablo 2.41 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.41. NB'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	1532	615
	İntihar Değil	506	1418

Tablo 2.41'de gösterildiği gibi, NB algoritması toplam 4071 tweetten 2950 tweeti doğru sınıflandırmış ve 1121 tweeti yanlış sınıflandırmıştır. NB için TP 1532, FP 615, FN 506 ve TN 1418'dir.

Tablo 2.42 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.42. RF'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	2116	802
	İntihar Değil	918	2271

Tablo 2.42'de gösterildiği gibi, RF algoritması toplam 6107 tweetten 2918 tweeti doğru sınıflandırmış ve 1720 tweeti yanlış sınıflandırmıştır. RF için TP 2116, FP 802, FN 918 ve TN 2271'dir.

Tablo 2.43 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.43. DT'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	2217	1140
	İntihar Değil	817	1933

Tablo 2.43'de gösterildiği gibi, DT algoritması toplam 6107 tweetten 4150 tweeti doğru sınıflandırmış ve 1957 tweeti yanlış sınıflandırmıştır. DT için TP 2217, FP 1140, FN 817 ve TN 1933'tür.

Tablo 2.44 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.44. KNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	332	290
	İntihar Değil	125	253

Tablo 2.44'te gösterildiği gibi, KNN algoritması toplam 1000 tweetten 585 tweeti doğru sınıflandırmış ve 415 tweeti yanlış sınıflandırmıştır. KNN için TP 332, FP 290, FN 125 ve TN 253'tür.

2.6.11. Reddit Depression Suicidewatch veri seti için grid search uygulanan derin öğrenme modellerinin sonuçları

Tablo 2.45 ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.45. ANN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	1371	544
	İntihar Değil	667	1489

Tablo 2.45'te gösterildiği gibi, ANN algoritması toplam 4071 tweetten 2860 tweeti doğru sınıflandırmış ve 1211 tweeti yanlış sınıflandırmıştır. ANN için TP 1371, FP 544, FN 667 ve TN 1489'dur.

Şekil 2.33'te ANN algoritmasının training accuracy ve test accuracy grafiklerini göstermiştir.



Şekil 2.33. ANN için training accuracy ve test accuracy grafikleri


Tablo 2.46 LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.46. LSTM'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	1474	552
İntihar Değil	564	1481

Tablo 2.46'da gösterildiği gibi, LSTM algoritması toplam 4071 tweetten 2860 tweeti doğru sınıflandırmış ve 1211 tweeti yanlış sınıflandırmıştır. LSTM için TP 1474, FP 552, FN 564 ve TN 1481'dir.

Şekil 2.34'te LSTM algoritmasının training loss ve training accuracy grafiklerini göstermiştir.

**Şekil 2.34.** LSTM için training loss ve training accuracy grafikleri


Tablo 2.47 DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.47. DBN'nin karmaşıklık matrisi

Tahmini değerler	Gerçek değerler	
	İntihar	İntihar Değil
İntihar	1406	568
İntihar Değil	532	1465

Tablo 2.47'de gösterildiği gibi, DBN algoritması toplam 3971 tweetten 2871 tweeti doğru sınıflandırmış ve 1100 tweeti yanlış sınıflandırmıştır. DBN için TP 1406, FP 568, FN 532 ve TN 1465'dir.

Şekil 2.35'te DBN algoritmasının training loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.35. DBN için training loss ve validation accuracy grafikleri


Tablo 2.48 CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.48. CNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	1588	729
	İntihar Değil	450	1304

Tablo 2.48'de gösterildiği gibi, CNN algoritması toplam 4071 tweetten 2892 tweeti doğru sınıflandırmış ve 1179 tweeti yanlış sınıflandırmıştır. CNN için TP 1588, FP 729, FN 450 ve TN 1304'dir.

Şekil 2.36'da CNN algoritmasının training accuracy ve validation accuracy grafiklerini göstermiştir.



Şekil 2.36. CNN için training accuracy ve validation accuracy grafikleri

2.6.12. Suicide Detection veri seti için grid search uygulanan makine öğrenmesi modellerinin sonuçları

Tablo 2.49 LR için karmaşıklık matrisini göstermektedir.

Tablo 2.49. LR'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	21924	1784
	İntihar Değil	1363	21344

Tablo 2.49'da gösterildiği gibi, LR algoritması toplam 46415 tweetten 43268 tweeti doğru sınıflandırmış ve 3147 tweeti yanlış sınıflandırmıştır. LR için TP 21924, FP 1784, FN 1363 ve TN 21344'tür.

Tablo 2.50 NB için karmaşıklık matrisini göstermektedir.

Tablo 2.50. NB'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	19443	1119
	İntihar Değil	3844	22009

Tablo 2.50'de gösterildiği gibi, NB algoritması toplam 46415 tweetten 41452 tweeti doğru sınıflandırmış ve 4963 tweeti yanlış sınıflandırmıştır. NB için TP 19443, FP 1119, FN 3844 ve TN 22009'dur.

Tablo 2.51 RF için karmaşıklık matrisini göstermektedir.

Tablo 2.51. RF'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	31590	8451
	İntihar Değil	3234	26348

Tablo 2.51'de gösterildiği gibi, RF algoritması toplam 69623 tweetten 57938 tweeti doğru sınıflandırmış ve 11685 tweeti yanlış sınıflandırmıştır. RF için TP 31590, FP 8451, FN 3234 ve TN 26348'dir.

Tablo 2.52 DT için karmaşıklık matrisini göstermektedir.

Tablo 2.52. DT'nin karmaşıklık matrisi

		Gerçek değerler	
Tahmini değerler		İntihar	İntihar Değil
	İntihar	31388	6307
	İntihar Değil	3436	28492

Tablo 2.52'de gösterildiği gibi, DT algoritması toplam 69623 tweetten 59880 tweeti doğru sınıflandırmış ve 9743 tweeti yanlış sınıflandırmıştır. DT için TP 31388, FP 6307, FN 3436 ve TN 28492'dir.

Tablo 2.53 KNN için karmaşıklık matrisini göstermektedir.

Tablo 2.53. KNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	20348	6343
	İntihar Değil	2939	16785

Tablo 2.53'te gösterildiği gibi, KNN algoritması toplam 46415 tweetten 37133 tweeti doğru sınıflandırmış ve 9282 tweeti yanlış sınıflandırmıştır. KNN için TP 20348, FP 6343, FN 2939 ve TN 16785'dir.

2.6.13. Suicide Detection veri seti için Grid Search uygulanan derin öğrenme modellerinin sonuçları


Tablo 2.54 CNN için karmaşıklık matrisini göstermektedir.

Tablo 2.54. CNN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	2230	226
	İntihar Değil	175	2011

Tablo 2.54'te gösterildiği gibi, CNN algoritması toplam 4642 tweetten 4241 tweeti doğru sınıflandırmış ve 401 tweeti yanlış sınıflandırmıştır. CNN için TP 2230, FP 226, FN 175 ve TN 2011'dir.

Şekil 2.37'de CNN algoritmasının training accuracy ve training loss grafiklerini göstermiştir.



Şekil 2.37. CNN için training accuracy ve training loss grafikleri


Tablo 2.55 LSTM için karmaşıklık matrisini göstermektedir.

Tablo 2.55. LSTM'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler		İntihar	İntihar Değil
	İntihar	992	147
	İntihar Değil	207	975

Tablo 2.55'te gösterildiği gibi, LSTM algoritması toplam 2321 tweetten 1967 tweeti doğru sınıflandırmış ve 354 tweeti yanlış sınıflandırmıştır. LSTM için TP 992, FP 147, FN 207 ve TN 975'dir.

Şekil 2.38'de LSTM algoritmasının training loss ve training accuracy grafiklerini göstermiştir.



Şekil 2.38. LSTM için training loss ve training accuracy grafikleri


Tablo 2.56 DBN için karmaşıklık matrisini göstermektedir.

Tablo 2.56. DBN'nin karmaşıklık matrisi

Gerçek değerler			
Tahmini değerler	İntihar	İntihar Değil	
	İntihar	17736	1936
	İntihar Değil	5551	21192

Tablo 2.56'da gösterildiği gibi, DBN algoritması toplam 46415 tweetten 38928 tweeti doğru sınıflandırmış ve 7487 tweeti yanlış sınıflandırmıştır. DBN için TP 17736, FP 1936, FN 5551 ve TN 21192'dir.

Şekil 2.39'da DBN algoritmasının education loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.39. DBN için education loss ve validation accuracy grafikleri


Tablo 2.57 ANN için karmaşıklık matrisini göstermektedir.

Tablo 2.57. ANN'nin karmaşıklık matrisi

		Gerçek değerler	
		İntihar	İntihar Değil
Tahmini değerler	İntihar	11023	755
	İntihar Değil	652	10778

Tablo 2.57'de gösterildiği gibi, ANN algoritması toplam 23208 tweetten 21801 tweeti doğru sınıflandırmış ve 1407 tweeti yanlış sınıflandırmıştır. ANN için TP 11023, FP 755, FN 652 ve TN 10778'dir.

Şekil 2.40'da ANN algoritmasının training loss ve validation accuracy grafiklerini göstermiştir.



Şekil 2.40. ANN için training loss ve validation accuracy grafikleri

2.6.14. İncelenen üç veri setinin karşılaştırmalı Grid Search sonuçları

Tablo 2.58 Suicide Ideation veri seti için yöntemlerin metriklerle göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.58. Suicide Ideation veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
CNN	0.71	0.71	0.88	0.79
LSTM	0.91	0.93	0.93	0.93
DBN	0.84	0.87	0.88	0.87
ANN	0.59	0.59	1.00	0.74
Lojistik Regresyon	0.93	0.93	0.97	0.95
Naive Bayes	0.87	0.97	0.82	0.89
Random Forest	0.94	0.94	0.97	0.95
Decision Tree	0.90	0.92	0.92	0.92
KNN	0.76	0.72	1.00	0.83

Tablo 2.58'deki sonuçlara göre, RF yöntemi Doğruluk, LR ve RF F-Skoru metriklerinde en iyi sonucu almıştır. ANN ve KNN yöntemleri Hassasiyet metriğinde en iyi sonucu almış, Kesinlik metriğinde ise NB yöntemi en iyi sonucu almıştır.

Tablo 2.59 Reddit Depression Suicidewatch veri seti için yöntemlerin metriklere göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.59. Reddit Depression Suicidewatch veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
CNN	0.71	0.69	0.78	0.73
LSTM	0.72	0.73	0.72	0.73
DBN	0.70	0.71	0.69	0.70
ANN	0.74	0.72	0.67	0.69
Lojistik Regresyon	0.73	0.73	0.71	0.72
Naive Bayes	0.72	0.71	0.75	0.73
Random Forest	0.71	0.73	0.70	0.71
Decision Tree	0.67	0.66	0.73	0.69
KNN	0.58	0.53	0.73	0.62

Tablo 2.59'daki sonuçlara göre, ANN yöntemi Doğruluk, CNN,LSTM ve NB F-Skoru metriklerinde en iyi sonucu almıştır. CNN yöntemi Hassasiyet metriğinde en iyi sonucu almış ,Kesinlik metriğinde ise LSTM,LR ve RF yöntemleri en iyi sonucu almıştır.

Tablo 2.60 Suicide Detection veri seti için yöntemlerin metriklere göre karşılaştırmalı sonuçlarını göstermektedir.

Tablo 2.60. Suicide Detection veri seti için yöntemlerin karşılaştırmalı sonuçları

Algoritma	Doğruluk	Kesinlik	Hassasiyet	F-Skoru
CNN	0.91	0.92	0.90	0.91
LSTM	0.84	0.87	0.83	0.85
DBN	0.83	0.90	0.76	0.83
ANN	0.93	0.94	0.94	0.94
Lojistik Regresyon	0.93	0.92	0.94	0.93
Naive Bayes	0.89	0.95	0.83	0.89
Random Forest	0.83	0.79	0.91	0.84
Decision Tree	0.86	0.83	0.90	0.87
KNN	0.80	0.76	0.87	0.81

Tablo 2.60'daki sonuçlara göre, LR ve ANN yöntemi Doğruluk, F-Skoru metriğinde en iyi sonucu ANN almıştır. LR ve ANN yöntemleri Hassasiyet metriğinde en iyi sonucu almış, Kesinlik metriğinde ise NB yöntemi en iyi sonucu almıştır.

2.6.15. Derin öğrenme yöntemlerinin parametreleri

Tablo 2.61 Suicide Ideation veri seti için derin öğrenme yöntemlerinin parametrelerini göstermektedir.

Tablo 2.61. Suicide Ideation veri seti için derin öğrenme yöntemlerinin parametreleri

Algoritma	Ara Katman Etkinleştirme Fonksiyonu	Gizli Katman Boyutları	Optimizer/Öğrenme Oranı
CNN	ReLu	64	Adam/0.01
LSTM	Tanh	32	Adam/0.01
DBN	ReLu	512,256	Sgd/0.01
ANN	ReLu	100,50	Adam/0.01

Tablo 2.62 Reddit Depression Suicidewatch veri seti için derin öğrenme yöntemlerinin parametrelerini göstermektedir.

Tablo 2.62. Reddit Depression Suicidewatch veri seti için derin öğrenme yöntemlerinin parametreleri

Algoritma	Ara Katman Etkinleştirme Fonksiyonu	Gizli Katman Boyutları	Optimizer/Öğrenme Oranı
CNN	ReLu	128	Adam/0.01
LSTM	Tanh	512,256	Sgd/0.007
DBN	ReLu	512,256	Sgd/0.01
ANN	Logistic	50	Adam/0.01

Tablo 2.63 Suicide Detection veri seti için derin öğrenme yöntemlerinin parametrelerini göstermektedir.

Tablo 2.63. Suicide Detection veri seti için derin öğrenme yöntemlerinin parametreleri

Algoritma	Ara Katman Etkinleştirme Fonksiyonu	Gizli Katman Boyutları	Optimizier/Öğrenme Oranı
CNN	ReLu	32	Adam/0.01
LSTM	Tanh	128,64	Adam/0.01
DBN	ReLu	128	Adam/0.01
ANN	ReLu	100	Adam/0.001

3. SONUÇ VE ÖNERİLER

Ruh sağlığı sorunları dünya genelinde giderek artmaktadır. Toplumsal bir sağlık sorunu haline gelen psikolojik rahatsızlıklar çeşitli sonuçlar doğurmaktadır. Bu rahatsızlıkların en önemlilerinden biri olan depresyon sonucunda kişiler intihar edebilmektedir. Kişinin kendi isteğiyle yaşamına son vermesi olan intihar davranışı, kişinin kendisine yönelttiği bir saldırganlık -öfkenin içe dönmesi- halidir. Bu olgu, ciddi bir duygusal ve iletişimsel sorunun belirtisi olarak görülmektedir. İntihar eğilimlerinin geleneksel olarak tespit edilmesinin yanı sıra günümüzde kişilerin sosyal ağlardaki paylaşımlarından da intihar eğilimleri önceden tespit edilebilmekte ve gerekli önlemlerin alınmasına katkı sağlamaktadır. Derin öğrenme ve makine öğrenmesi yöntemleri, çevrimiçi sosyal ağlarda depresyon ve intihar tespiti konusunda büyük bir potansiyele sahiptir. Doğal Dil İşleme, görsel içerik analizi ve çoklu modalite veri entegrasyonu gibi yöntemler, bu tür ruh sağlığı sorunlarının erken teşhis edilmesine ve müdahale edilmesine yardımcı olabilir. Ancak, bu teknolojilerin kullanımında etik sorumlulukların göz önünde bulundurulması ve bu sistemlerin doğruluğunu arttırmak için sürekli olarak geliştirilmesi gerekmektedir.

Bu tez çalışmasında ANN, DBN, CNN, LSTM, FastText, NB, LR, k-NN, RF ve DT yöntemleri kullanılarak intihar düşüncesi tahmin modelleri oluşturulmuş makine öğrenmesi yöntemlerine TF-IDF ve derin öğrenme modellerine ise FastText uygulanmıştır. Ayrıca hiperparametre optimizasyonu için bütün algoritmalara Grid Search yöntemi uygulanarak sonuçlar karşılaştırılmıştır. Tez çalışmasının ilk karşılaştırmalar sonucunda Suicide Ideation veri setinde %94 oranıyla RF modeli, Reddit Depression Suicidewatch veri setinde %73 oranıyla LR modeli ve Suicide Detection veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur. Grid Search metriği uygulandıktan sonraki karşılaştırmalar sonucunda ise Suicide Ideation veri setinde %94 oranıyla RF modeli, Reddit Depression Suicidewatch veri setinde %74 oranıyla ANN modeli ve Suicide Ideation veri setinde ise %93 oranıyla ANN ve LR en başarılı modeller olmuştur.

4.KAYNAKLAR

- Arikan, K.**, 2023. İntihar nedir, intihar önlenebilir mi?
<https://www.kemalarikan.com/intihar-nedir-intihar-onlenebilir-mi.html>, 20 Mayıs 2023.
- Angskun, J., Tipprasert, S., Angskun, T.**, 2022. Big data analytics on social networks for real-time depression detection. *Journal of Big Data*, 9(1):69.
- Bergstra, J., Bardenet, R., Bengio, Y., Kégl, B.**, 2013. Algorithms for hyper-parameter optimization. *The 25th Annual Conference on Neural Information Processing Systems*, Lake Tahoe, USA, December 5-10.
- Bengio, Y., Courville, A., & Vincent, P.**, 2013. Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8):1798-1828.
- Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T.**, 2017. Enriching word vectors with subword information. *Transactions of the Association for Computational Linguistics*, 5:135-146.
- Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H.**, 2007. Greedy layer-wise training of deep networks. *In Advances in Neural Information Processing Systems*, Vancouver, Canada, December 2007, 153-160.
- Burnap, P., Colombo, G., Amery, R., Hodorog, A., & Scourfield, J.**, 2017. Multi-class machine classification of suicide-related communication on Twitter. *Online Social Networks and Media*, 2:32-44.
- Biau, G., Scornet, E.**, 2016. A random forest guided tour. *Test*, 25:197-227.
- Baltrušaitis, T., Ahuja, C., & Morency, L. P.**, 2018. Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2):423-443.
- Bengio, Y., Courville, A., & Vincent, P.**, 2013. Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8):1798-1828.
- Brownlee, J.**, 2020. Deep Learning Hyperparameters: A Practical Guide.
<https://machinelearningmastery.com/a-practical-guide-to-deep-learning-hyperparameters/>, 10 Şubat 2025.
- Barabási, A. L.**, 2002. *Linked: The New Science of Networks*. Perseus Publishing.
- Bergstra, J., Bengio, Y.**, 2012. Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13:281-305.
- Cunningham, P., Delany, S. J.**, 2021. k-Nearest neighbour classifiers - A Tutorial. *ACM Computing Surveys (CSUR)*, 54(6):1-25.
- Calvo, R. A., Milne, D. N., Hussain, M. S., Christensen, H.**, 2017. Natural language processing in mental health applications using non-clinical texts. *Natural Language Engineering*, 23(5):649-685.

- Cheng, X., Wang, Y., & Zhang, H.,** 2020. Detecting suicidal ideation on Twitter using CNN and SVM. *Journal of Medical Internet Research*, 22(6):e17535.
- Chollet, F.,** 2017. *Deep Learning with Python*. Manning Publications.
- De Choudhury, M., Gamon, M., Counts, S., & Horvitz, E.,** 2013. Predicting depression via social media. *Proceedings of the 7th International Conference on Weblogs and Social Media*, Boston USA, July 2013, 1-10.
- Guntuku, S. C., Yaden, D. B., Kern, M. L., Ungar, L. H., & Eichstaedt, J. C.,** 2017. Detecting depression and mental illness on social media: an integrative review. *Current Opinion in Behavioral Sciences*, 18:43-49.
- Goodfellow, I., Bengio, Y., & Courville, A.,** 2016. *Deep Learning*. MIT Press, Cambridge.
- Hegerl, U., & Wittenburg, L.,** 2009. The European Alliance Against Depression: A multilevel approach to the prevention of suicidal behavior. *Crisis*, 30(6):281-283.
- Hawton, K., & van Heeringen, K.,** 2009. Suicide. *The Lancet*, 373(9672):1372-1381.
- Hutter, F., Kotthoff, L., Vanschoren, J.,** 2019. *Automated Machine Learning: Methods, Systems, Challenges*. Springer-Verlag, Berlin.
- Hochreiter, S., & Schmidhuber, J.,** 1997. Long short-term memory. *Neural Computation*, 9(8):1735-1780.
- Hinton, G. E., Osindero, S., & Teh, Y. W.,** 2006. A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7):1527-1554.
- Hassan, A., Rahman, A., & Karim, M.,** 2021. A comparative study of LSTM and GRU for depression detection from social media. *IEEE Access*, 9:45678-45690.
- Kumar, M., & Dredze, M.,** 2020. Detecting changes in suicide-related language on social media following celebrity suicides. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, 26-30 October 2020, ABD, 1123-1132.
- Kotsiantis, S. B.,** 2013. Decision trees: a recent overview. *Artificial Intelligence Review*, 39:261-283.
- Kim, Y.,** 2014. Convolutional neural networks for sentence classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, 25-29 October, 1746-1751.
- Kumar, R., Singh, S., & Gupta, A.,** 2019. Detecting suicidal ideation on social media: A comparison of Naive Bayes and SVM. *New Media & Society*, 23(5): 934-951.
- Kim, S., Park, H., & Lee, K.,** 2021. A comparison of CNN and RNN for detecting suicidal ideation on social media platforms. *Journal of Affective Disorders*, 290:376-383.
- Liu, X., Sun, J., Yu, N. X., Sun, B., Li, Q., Zhu, T.,** 2019. Proactive suicide prevention online (PSPO): machine identification and crisis management for Chinese social media users with suicidal thoughts and behaviors. *Journal of medical internet research*, 21(5):e11705.

- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P.,** 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278-2324.
- LeCun, Y., Bengio, Y., & Hinton, G.,** 2015. Deep learning. *Nature*, 521(7553):436-444.
- Liu, C., & Hwa, R.,** 2020. Adversarial examples for models of code-switching. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, ABD, 5-10 July, 4823-4833.
- Lee, K., Kim, Y., & Park, J.,** 2019. Using BERT for depression and suicide risk detection from social media text. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, Seattle, Washington, ABD, July 2019, 4353-4363 (in English).
- Lia, R. J., Siddikk, A. B., Muntasir, F., Rahman, S. S. M. M., Jahan, N.,** 2022. Depression detection from social media using Twitter's tweet. In *Big Data Intelligence for Smart Applications*, pp. 485-493, eds. Springer, Singapore.
- LaValley, M. P.,** 2008. Logistic regression. *Circulation*, 117(18):2395-2399.
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L.,** 2016. The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2):2053951716679679.
- Mikolov, T., Chen, K., Corrado, G., & Dean, J.,** 2013. Efficient estimation of word representations in vector space. <http://arxiv.org/abs/1301.3781>, 21 Mart 2008.
- Mustafa, R. U., Ashraf, N., Ahmed, F. S., Ferzund, J., Shahzad, B., Gelbukh, A.,** 2020. A multiclass depression detection in social media based on sentiment analysis. In *17th International Conference on Information Technology–New Generations (ITNG 2020)*, Nevada, Las Vegas, ABD, 5-8 April, 659-662 (in English).
- Malhotra, A., Jindal, R.,** 2022. Deep learning techniques for suicide and depression detection from online social media: A scoping review. *Applied Soft Computing*, 109713.
- Mann, J. J., Apter, A., Bertolote, J., Beautrais, A., Currier, D., Haas, A., & Hegerl, U.,** 2005. Suicide prevention strategies: A systematic review. *JAMA*, 294(16):2064-2074.
- Nguyen, T., Pham, D., & Huynh, T.,** 2022. Comparison of CNN and LSTM for depression and suicide detection on social media. *Information*, 11(9):443.
- Newman, M.E.J.,** 2003. The structure and function of complex networks. *SIAM Review*, 45(2):167-256.
- O'Dea, B., Wan, S., Batterham, P. J., Calear, A. L., Paris, C., & Christensen, H.,** 2015. Detecting suicidality on Twitter. *Internet Interventions*, 2(2):183-188.
- Patel, S., Verma, P., & Shah, D.,** 2020. Using k-NN and Random Forest to detect depression in social media posts. *PLOS ONE*, 15(8):e0237251.
- Park, M., McDonald, D. W., & Cha, M.,** 2013. Perception differences between the depressed and non-depressed users in Twitter. *Proceedings of the 7th International Conference on Weblogs and Social Media*, Boston, Massachusetts, USA, 8-10 July, 123-126.

- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E.,** 2011. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12: 2825-2830.
- Reece, A. G., & Danforth, C. M.,** 2017. Instagram photos reveal predictive markers of depression. *EPJ Data Science*, 6(1):15.
- Renjith, S., Abraham, A., Jyothi, S. B., Chandran, L., Thomson, J.,** 2022. An ensemble deep learning technique for detecting suicidal ideation from posts in social media platforms. *Journal of King Saud University-Computer and Information Sciences*, 34(10): 9564-9575.
- Reddy, E. M. K., Gurralla, A., Hasitha, V. B., & Kumar, K. V. R.,** 2022. Introduction to Naive Bayes and a Review on Its Subtypes with Applications. *Bayesian Reasoning and Gaussian Processes for Machine Learning Applications*, pp. 1-14, eds. In H. K., S. Tayal, P. M. George, P. Singla, & U. Kose (Eds.), Chapman and Hall/CRC.
- Sparck Jones, K.,** 1972. A statistical interpretation of term specificity and its application in retrieval. *Journal of Documentation*, 28(1):11-21.
- Smith, J., Johnson, P., & Lee, S.,** 2021. Depression detection from social media using deep learning models: A comparison of LSTM and GRU. *Expert Systems with Applications*, 168:114376.
- Trifan, A., Antunes, R., Matos, S., Oliveira, J. L.,** 2020. Understanding depression from psycholinguistic patterns in social media texts. In *European Conference on Information Retrieval*, Cham, Springer International Publishing, 14-17 April 2020, 402-409(in English).
- Tadesse, M. M., Lin, H., Xu, B., Yang, L.,** 2019. Detection of depression-related posts in Reddit social media forum. *IEEE Access*, 7:44883-44893.
- URL-1,** 2019. World Health Organization. Mental Health. http://www.who.int/mental_health/en/. 10 Nisan 2023.
- URL-2,** 2017. Pan American Health Organization. Depression. https://www3.paho.org/hq/index.php?option=com_topics&view=article&id=212&Itemid=40872&la=&lang=en#gsc.tab=0. 12 Mayıs 2023.
- URL-3,** 2020. World Health Organization. Depression. <https://www.who.int/news-room/fact-sheets/detail/depression>. 31 Mart 2023.
- URL-4,** 2013. American Psychiatric Association. DSM. <https://www.psychiatry.org/psychiatrists/practice/dsm>. 21 Ekim 2024.
- URL-5,** 2002. Psychopharmacology Bulletin. Role of GABA in anxiety. <https://www.psychopharmacologybulletin.org/article/role-of-GABA-anxiety>. 21 Ekim 2024.
- URL-6,** 1967. University of Pennsylvania Press. Depression: Causes and Treatment. <https://www.upenn.edu/press/book/depression-causes-treatment>. 21 Ekim 2024.

- URL-7**, 1973. Journal of Psychosomatic Research. Social relationships and depression. <https://www.journalofpsychosomaticresearch.com/article/social-relationships-depression>. 21 Ekim 2024.
- URL-8**, 2000. Journal of Consulting and Clinical Psychology. Depression treatment outcomes. <https://doi.org/10.1037/0022-006X.68.3.471>. 21 Ekim 2024.
- URL-9**, 2007. Current Opinion in Psychiatry. GABA and anxiety. <https://doi.org/10.1097/YCO.0b013e3282f8c5b1>. 21 Ekim 2024.
- URL-10**, 2024. <https://thedatavers.com/index.php/2024/03/26/understanding-feature-scaling-in-machine-learning/>. Understanding Feature Scaling in Data Preprocessing for Machine Learning. 1 Kasım 2024.
- Williams, D., Jones, T., & Brown, M.**, 2021. Utilizing BERT for depression detection from social media text. *Frontiers in Psychology*, 12:708610.
- Wellman, B.**, 2001. Computer networks as social networks. *Science*, 293(5537):2031-2034.
- Zhang, W., Liu, Y., & Chen, J.**, 2020. Depression detection from social media using Random Forest and SVM: A comparative study. *Journal of Medical Internet Research*, 22(10): e19165.

ÖZGEÇMİŞ

